深入理解
Android内核设计思想

林学森 著

中国工信出版集团　人民邮电出版社

深入理解

Android内核设计思想

林学森 著

中国工信出版集团 人民邮电出版社
POSTS & TELECOM PRESS

版权信息

书名：深入理解Android内核设计思想(第2版)(上下册)
作者：林学森
排版：昷一
出版社：人民邮电出版社
出版时间：2017-07-01
ISBN：9787115452634

内容提要

全书从操作系统的基础知识入手，全面剖析进程/线程、内存管理、Binder机制、GUI显示系统、多媒体管理、输入系统、虚拟机等核心技术在Android中的实现原理。书中讲述的知识点大部分来源于工程项目研发，因而具有较强的实用性，希望可以让读者"知其然，更知其所以然"。本书分为编译篇、系统原理篇、应用原理篇、系统工具篇，共4篇25章，基本涵盖了参与Android开发所需具备的知识，并通过大量图片与实例来引导读者学习，以求尽量在源码分析外为读者提供更易于理解的思维方式。

本书既适合Android系统工程师，也适合于应用开发工程师来阅读，从而提升Android开发能力。读者可以在本书潜移默化的学习过程中更深刻地理解Android系统，并将所学知识自然地应用到实际开发难题的解决中。

第1版前言

写本书的原因

4次大幅改版，N次修订，前后历时近3年，本书终于要与读者见面了。

在这3年的时间里，Android系统不断更新换代，书本内容也尽可能紧随其步伐——我总是会在第一时间下载到工程源码，然后系统性地比对和研究每次改版后的差异。可以说本书伴随着Android的高速发展，完整地见证了它给大家带来的一次又一次惊喜。

在这么长的写作跨度中，有一个问题始终萦绕在我的脑海中，即“为什么写这本书”？

市面上讲解操作系统的著作很多，主要风格有两种。

- 理论型

高校中采用的操作系统教材多数属于这种类型。它们主要阐述通用的计算机理论与原理，一般不会针对某个具体的操作系统做详细剖析。这类书籍是我们进入计算机科学的“敲门砖”。只有基础打得扎实，研究市面上任何一款操作系统才能做到“有的放矢”。

- 实用型

这类书籍以讲解某个具体的操作系统为主，如市面上就有非常多的关于Windows和Linux系统的。前者因为不开源，谁也不可能深入代码级别进行讲解；而后者则恰恰相反，任何人都能轻松获取到完整的内核源码。在Linux之父经典名言“Read the f***king Source Code”的鼓励下，无数有志之士投入到“代码汪洋”的分析中，从中细细感受大师们的设计艺术。

那么本书属于什么类型呢？个人认为更贴切地说，就是上面两种的结合。

本书的一个主要宗旨是希望读者可以由浅入深地逐步理解Android系统的方方面面。因而在每章节内容的编排上，采用由整体到局部的线索铺展开来——先让读者有一个直观感性的认识，明白“是什么”“有什么用”，然后才剖析“如何做到的”。这样的一个好处是读者在学习过程中不容易产生困惑；否则如果直接切入原理，长篇大论地分析代码，仅一大堆函数调用就可能让人失去学习的方向。这样的结果往往是，读者花了非常多的时间来理清函数关系，但始终不明白代码编写者的意图，甚至连这些函数想实现什么功能都无法完全理解。

本书希望可以从更高的层次，即抽象的、反映设计者思想的角度去理解系统。而在思考的过程中，大部分情况下我们都将从读者容易理解的基础知识开始讲起。就好比画一张素描画一样——先给出一张白纸，勾勒出整体框架，然后针对重点部位细细加工，最后才能还原出完整的画面。另外，本书在对系统原理本身进行讲解的同时，也最大程度地结合工程项目中可能遇到的难点，理论联系实际地进行解析。希望这样的方式既能让读者真正学习到Android系统的设计思想，也能学有所用，增加一些实际的项目开发经验和技巧。

本书的主要内容

细心的读者会发现本书章节中包含了“Android和OpenGL ES”“信息安全基础概述”等看似与本书无关的内容——有些人可能会产生疑问，是否有此必要?

根据我们多年的Android项目开发和培训经验，答案就是“非常有必要”。举个例子，Android的显示系统是围绕OpenGL ES来展开的，后者是它的“根基”。但另外，并非所有开发人员都 深谙OpenGL ES。这样导致的结果就是他们在学习显示系统的过程中，有一种“四处碰壁”的感觉——实践证明，正是这些因素直接打击到了大家学习Android系统的信心。

因此我们在讲解系统实现原理之前，会最大程度地为读者提炼出所需的背景知识。有了这样的铺垫，相信对大家学习Android内核大有裨益。

本书在内容选择上依据的是“研发人员（包括系统开发和应用程序开发）参与实际Android项目所需具备的知识”，因而具有较强的实用性。全书共分为4篇，涵盖了编译、系统原理、应用原理和系统工具等多个方面。

其中第一篇不仅详细介绍了Android源码的下载及编译过程，为读者呈现了“Hello World”式的入门向导——更为重要的是，结合编译系统的架构和内部原理，为各厂家定制自己的Android产品提供了参考范例。

Android本质上只是市面上众多主流的操作系统之一。所以在系统原理的讲解过程中，我们将首先引导读者从计算机体系结构、经典的操作系统理论（比如进程/线程管理、进程间通信等）的角度来思考问题——包括Android在内的任何操作系统内核在实现过程中都“逃”不出这些经典的理论范畴。本书虽然是剖析Android系统的，但更希望读者

可以从中学到“渔”，而不仅仅是“鱼”。

从动态运行的角度来理解，Android内核是由众多系统服务组成的，如ActivityManagerService、GUI系统中的SurfaceFlinger、音频系统中的AudioFlinger、输入系统InputManagerService等。而各服务之间通信的基础就是Binder机制。本书在阐述它们错综复杂的关系中，遵循由“整体到局部”“由点及面”的科学方法，将知识点深入浅出地铺展开来，希望为读者全面理解Android内核提供“思维捷径”。

与其他讲解Android应用程序的书籍不同，本书在分析APK应用程序时的立足点是它的内部实现原理。如Intent匹配规则、应用程序的资源适配过程、字符编码的处理、Widget机制、应用程序的编译打包等都是应用开发人员在工作中经常会遇到的难题。通过系统性地解析隐藏在这些实现背后的原理，有助于他们彻底摆脱困惑，加深对应用开发的理解。

不论是系统工程师还是应用开发人员，Android调试工具都至关重要。但我们在实际工作中发现，不少研发人员对这些工具“只知其一，不知其二”。因而系统工具篇中将针对常用调试工具进行全面解析，希望由此可以让大家学习到如何“举一反三”，真正把它们的作用发挥得“淋漓尽致”。

本书的主要特点

（1）通过大量情景图片与实例引导读者学习，以求尽量在源码分析外为读者提供更易于理解的思维路径。

（2）作者在展开一个话题时，通常会由浅入深、由总体框架再到细节实现。这样可以保证读者能跟得上分析的节奏，并且“有根有据可循”，尽可能防止部分读者阅读技术书籍时“看了后面忘了前面”的现象。

（3）目前市面上不少Android书籍仍停留在Android 2.3或者更早期的版本。虽然原理类似，但对于开发人员来说，他们需要与项目研发相契合的技术书籍。本书希望尽可能紧随Android的更新步伐，为读者了解最新的Android技术提供帮助。

（4）本书的出发点仍是操作系统的经典原理，并以此为根基扩展分析Android中的具体实现机制——贯穿其中的是经久不衰的理论知识。

（5）本书所阐述的知识点大部分来源于工程项目研发的经验总结，因而具有较强的实用性，希望可以让读者“知其然，更知其所以然”。做到真正贴近读者，贴近开发需求。

致谢

感谢王益民董事长、钟宝英女士长期以来的关心、信任和支持——你们在很多方面都是我们学习的楷模。衷心祝愿王总企业蒸蒸日上、再创辉煌；衷心祝愿钟小姐事事顺心如意、永葆青春。

感谢人民邮电出版社的编辑，你们的专业态度和处理问题的人性化，是所有作者的“福音”。

感谢我的家人、长辈和朋友林进跃、林美玉、林惠忠、刘冰、林月明、温艳，感谢你们长期以来对我工作和生活上无微不至的关心和支持。

感谢所有读者的支持，是你们赋予了我写作的动力。另外，因为个人能力和水平有限，书中可能还有不足之处，希望读者不吝指教，一起探讨学习，作者的联系方式是：xuesenlin@alumni. cuhk.net。编辑联系和投稿邮箱是：zhangtao@ptpress.com.cn。

第2版前言

Android系统的诞生地——美国硅谷。

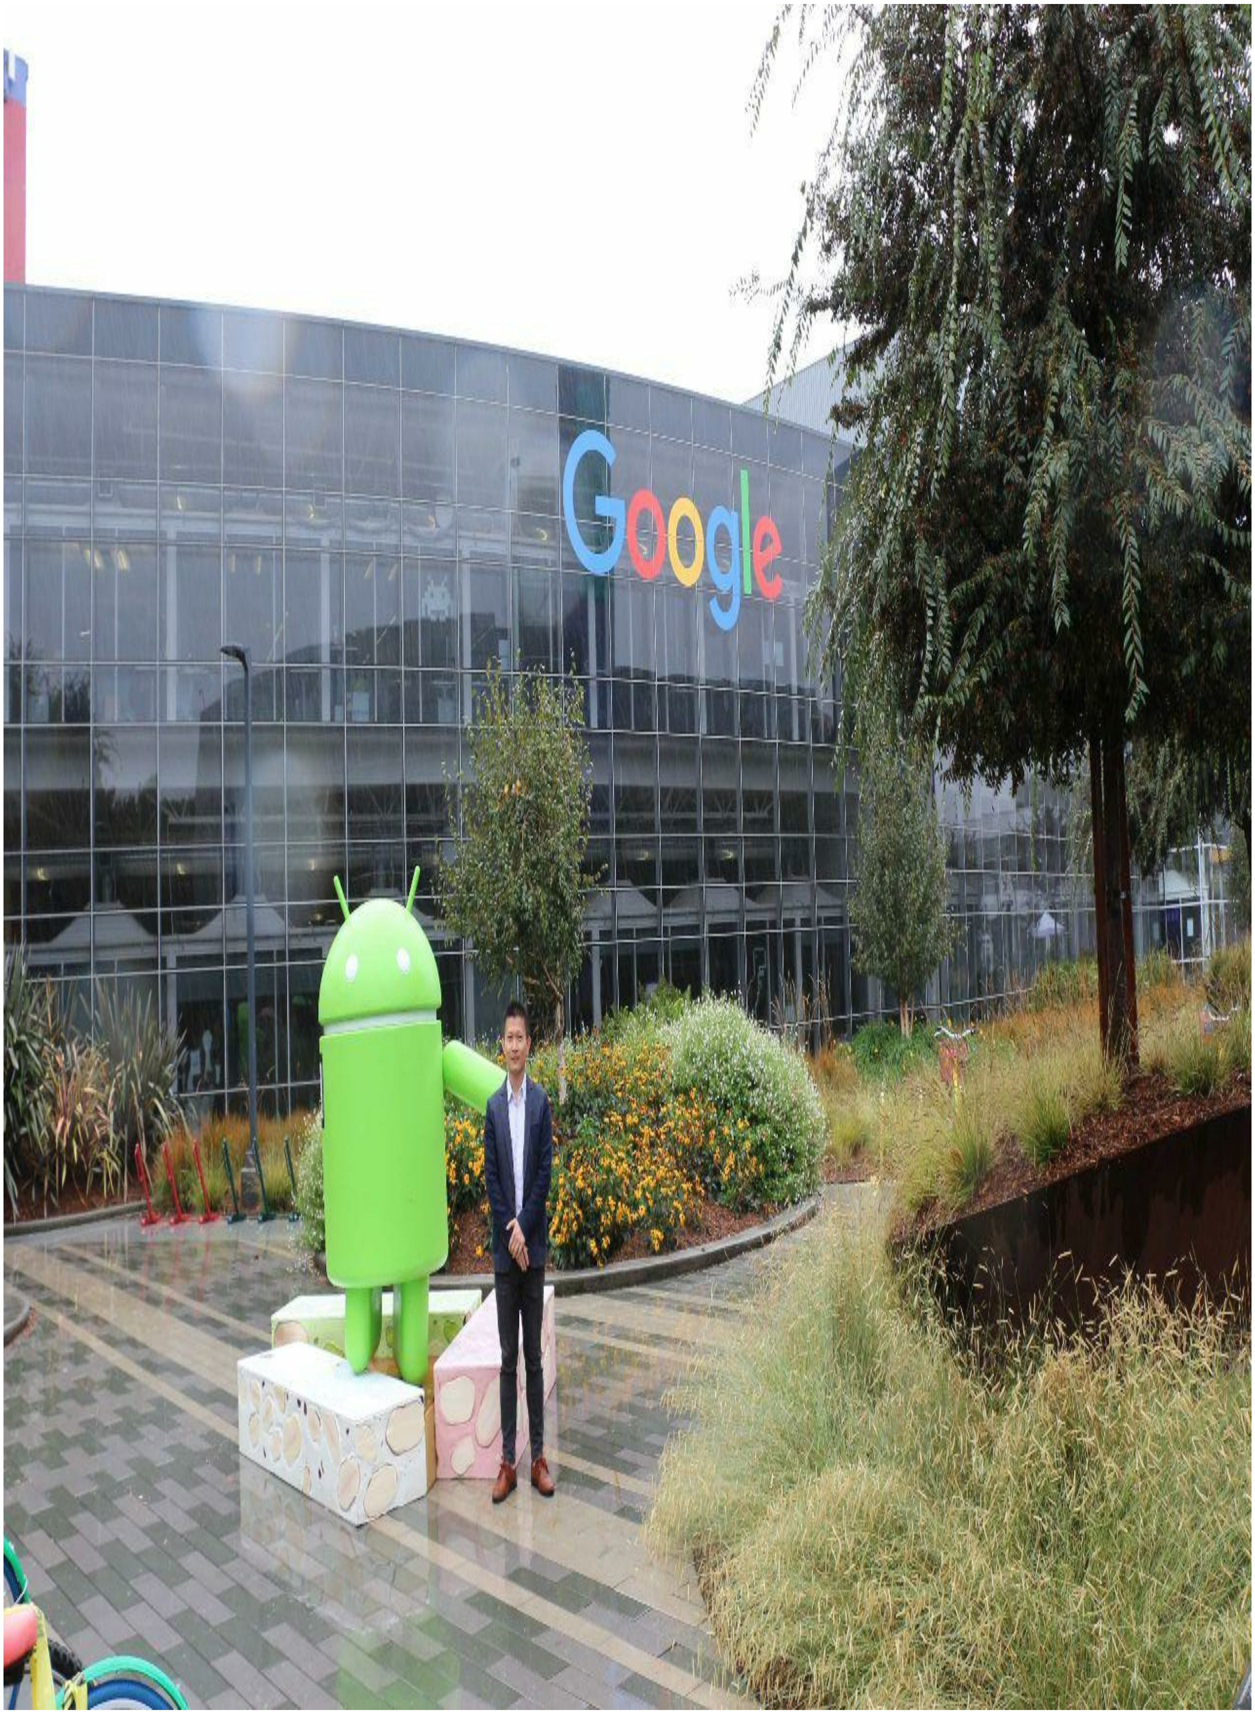
Google

2001

Google大楼前摆放着Android的最新版本雕塑，历史版本则被放置在Android Statues Park中

写第2版前言时，笔者刚好在美国加州硅谷等地公事出差访问。其间我一直在思考的问题是，美国硅谷（Silicon Valley）在近几十年时间里长盛不衰的原因是什么？技术的浪潮总是一波接着一波的，谁又会在不远的将来接替Google的Android系统，在操作系统领域成为下一轮的弄潮儿？我们又应该如何应对这种“长江后浪推前浪”的必然更迭呢？

从历史的长河来看，新技术、新事物的诞生往往和当时的大背景有着不可分割的关系。如果我们追溯硅谷的发展史，会发现其实它相对于美国很多传统地区来说还是非常年轻的。“硅谷”这个词是在1971年的“Silicon Valley in the USA”系列报导文章中才首次出现的。20世纪四五十年代开始，硅谷就像一匹脱了缰的野马一般，“一发不可收拾”。从早期的Hewlett-Packard公司，到仙童、AMD、Intel以及后来的Apple、Yahoo!等众多世界一流企业，硅谷牢牢把握住了科技界的几次大变革，成功汇集了美国90%以上的半导体产业，逐步呈现出“生生不息”的景象。

但为什么是硅谷，而不是美国其他地区成为高科技行业的“发动机”呢？

古语有云，“天时、地利、人和，三者不得，虽胜有殃”。

现在我们回过头来看这段历史，应该说硅谷早期的发展和当时的世界大环境有很大关系——更确切地说，正是美国国防工业的发展诉求，才给了硅谷创业初期的“第一桶金”。只有“先活下来，才有可能走得更远”。而接下来社会对半导体工业需求的爆炸式增长，同样让硅谷占据了“天时”的优势，再接再厉最终走上良性循环。

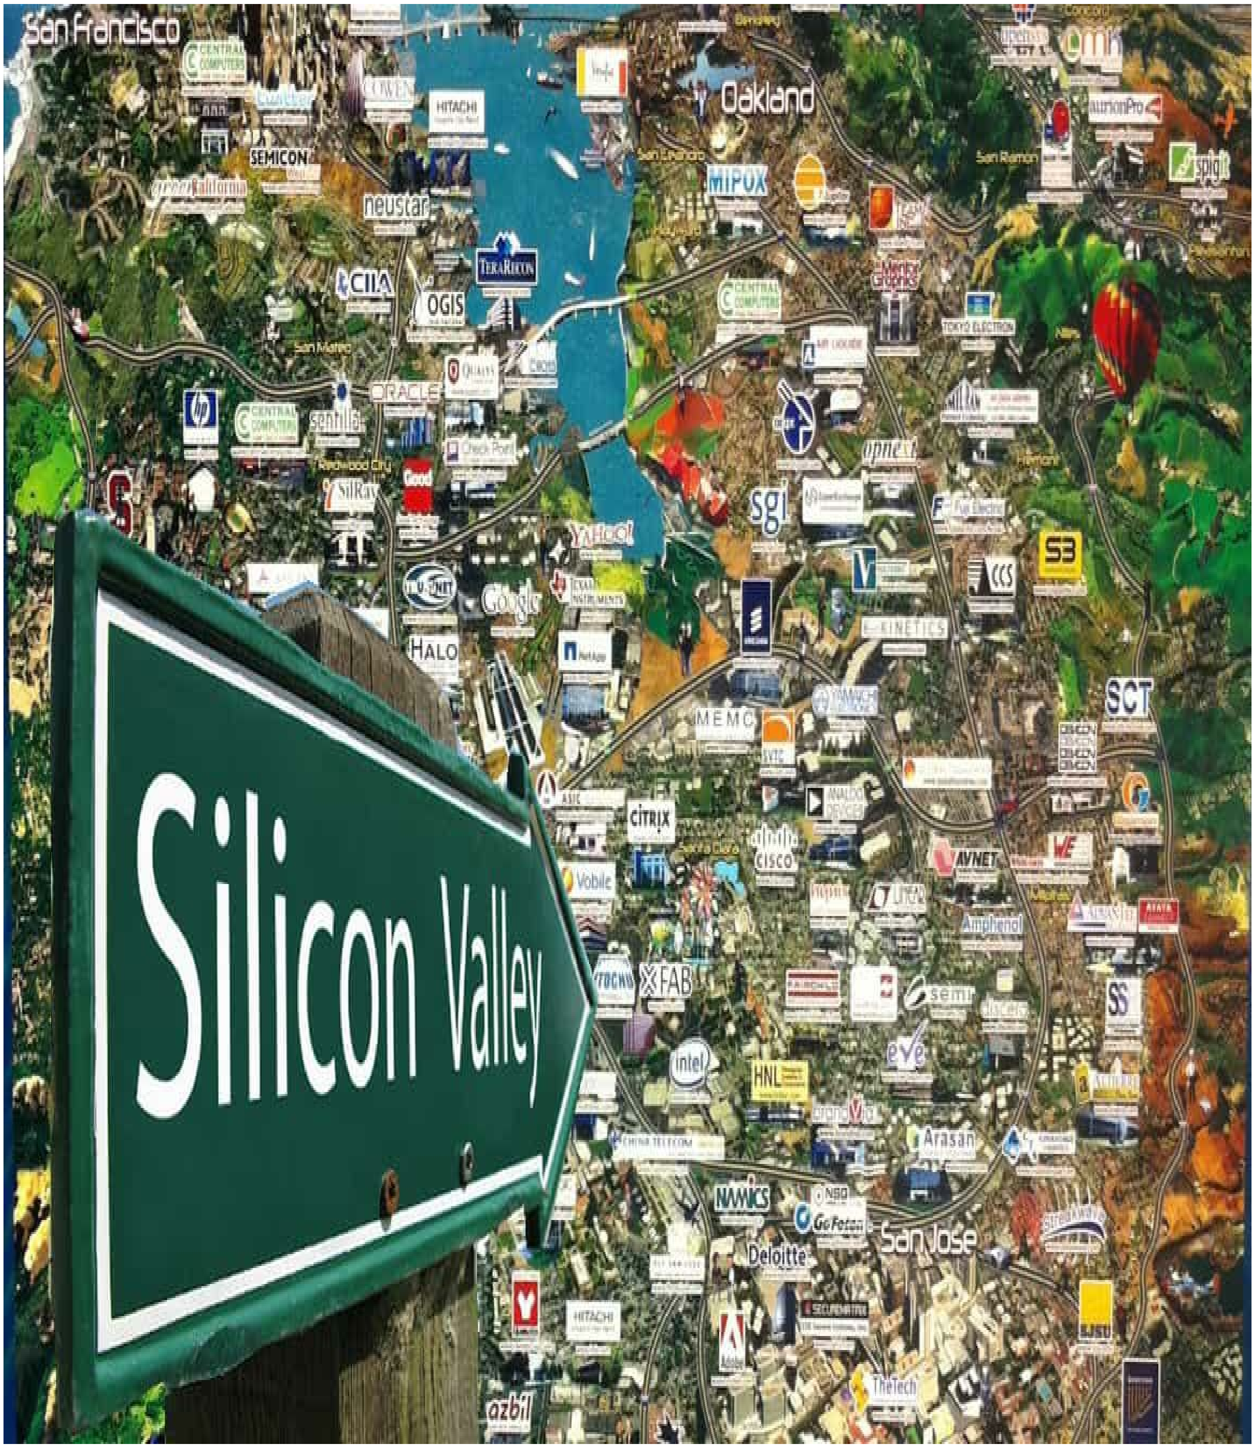

密密麻麻的硅谷大企业
（引用自cdn.com）

硅谷的“地利”和“人和”，可能主要体现在：

（1）Stanford University

斯坦福大学校园

Stanford University在硅谷的发展过程中起到了非常关键的作用。20世纪50年代的时候，这所大学还并不是很起眼，各方面条件都比较糟糕，她的毕业生也多数会去东海岸寻求就业机会。后来她的一位教授Frederick Terman看到了产业和学术的接合点，从学校里划分出一大块空地来鼓励学生创业，并且指导其中两位学生创立了Hewlett-Packard公司。随后的几年他又成立了Stanford Research Park，这也同时是后来全球各高科技园区的起点，并吸引了越来越多的公司加入。在那段时间里，相信起到核心催化作用的是“产”+“学”的高度结合——将科技产品不断推陈出新产生经济效益，然后再回馈到研究领域。在几十年的跨度里，很多顶尖公司（Google、Yahoo!、HP等）的创始人都出自该校。有统计显示Standford师生及校友创造了硅谷一半以上的总产值，其影响力可见一斑。

（2）便利的地理环境

整个硅谷地区面积并不是很大，属于温带海洋性气候，全年平均温度在13℃～24℃，污染很小。同时，它依林傍海，陆、海、空都可以很好地与外界相连，这样一来自然有利于人才的引入。

（3）鼓励创新，完善的专利保护机制

从法律上讲，硅谷每年有超过4000项的专利申请，工程师和律师的比例达到了10∶1。在创新点得到保护的同时，也使得初创公司能够得到进一步的发展，从而避免它们被扼杀在摇篮中。从观念上来说，硅谷人对知识产权还是非常尊重的，他们大多认为剽窃是没有技术含量的，相当于“涸泽而渔”。

（4）完善的风投体系，并容忍失败

事实上在硅谷创业，其成本和失败率都很高——其中能存活3～5年的公司只有10%～20%。一方面，风险投资方需要高度容忍这样的失败率；另一方面，在允许快速试错的同时，风险投资方又可以从某些成功中获得巨大收益——硅谷就是一个可以达到这种矛盾平衡的神奇所在

地。

“三十年河东，三十年河西”，技术的浪潮总是在不断演进的。从Symbian、Black Berry，到Android、iOS，历史经验告诉我们没有一项技术是会永远一成不变的。所以我们在技术领域的探索过程中，既要拿“鱼”，更要学会“渔”——前者是为当前的工作而努力，后者则是为我们的未来做投资。以Android操作系统为例，事实上我们除了“知其然”外，还更应该学习它的内部设计思想——即“知其所以然”。当我们真正地理解了那些“精华”所在以后，那么相信以后再遇到任何其他的操作系统，就都可以做到“触类旁通”了。也只有这样，或许才能在快速变革的科技领域中把握住脉搏，立于不败之地。

林学森

于美国硅谷

关于本书第2版

在第1版上市的这两年时间里，不断有读者来信分享他们阅读本书时的感想和心得，笔者首先要在这里衷心地向大家说声感谢！正是你们的支持和肯定，才有了《深入理解Android内核设计思想》（第2版）的诞生。

其中有不少读者提到了他们希望在本书后续更新中看到的内容，包括Android虚拟机的内部实现原理、Android的安全机制、Gradle自动化构建工具等——这些要求都在本次版本更新中得到了体现。

需要特别说明的是，第2版中的所有新增和有更新的部分都是基于Android最新的N版本展开的。由于Android版本的更新换代很快，且版本间的差异巨大，导致书中很多内容几乎需要全部重写。另外笔者写书都是在下班后的业余时间进行的，所以即便是每晚奋笔疾书到深夜，再加上周末和节假日时间（如果没有加班工作的话），最后发现更新全书所需时间依然要大于Android系统的发布间隔。为了让读者可以早日阅读到大家感兴趣的内容，本次版本的部分章节保留了第1版的原有内容——本书下一次再版时会争取将它们更新到Android的最新版本。这一点希望得到大家的谅解，谢谢！

致谢

感谢我目前任职公司的领导和同事们，是你们的帮助和支持，才让我更快地融入到了这个大家庭中。在一个到处都是“聪明人”和具有“狼性奋斗者”精神的公司里，每天的进步和知识积累都是让人愉悦的。

感谢人民邮电出版社的编辑，你们的专业态度和处理问题的人性化，是所有作者的“福音”。

感谢我的家人林进跃、张建山、林美玉、杨惠萍、林惠忠、林月明，没有你们的鼓励与理解，就没有本书的顺利出版。

感谢我的妻子张白杨的默默付出，是你工作之外还无怨无悔地在照顾着我们可爱的宝宝，才让我有充足的时间和精力来写作。

感谢所有读者的支持，是你们赋予了我写作的动力。另外，因为个人能力和水平有限，书中难免会有不足之处，希望读者不吝指教，一起探讨学习，作者的联系方式是：xuesenlin@alumni. cuhk.net。编辑联系和投稿邮箱是：zhangtao@ptpress.com.cn。本书读者交流QQ群为216840480。

作者

第1篇
Android编译篇

第1章 Android系统简介

第2章 Android源码下载及编译

第3章 Android编译系统

第1章

Android系统简介

美国当地时间2015年5月28日，“Google I/O 2016”大会在旧金山市的Moscone Center举行。

会议公布的官方数据如下：

- 全球已经激活的Android设备达到9亿次；
- Google Play中收录了超过70万的应用程序；
- 应用程序安装量达到480亿次；
- 132个以上的国家或地区销售Android设备；
- 超过190个国家或地区可以下载到免费的Android应用程序。

2016年，Google则直接把大会地址从传统的Moscone Center改到了Shoreline公园的户外，吸引了成千上万来自全球各地的科技爱好者。

从2008年9月Google发布Android 1.0版本开始，Android已经走过了8个年头。在这短短的几年间，这个以机器人为Logo的操作系统不仅席卷了全球各地的手机市场，而且与iOS、Windows Phone形成三足鼎立之势，更渗透到传统与新兴电子产业的方方面面。越来越多的电子产品已开始采用Android系统，如Android电视、平板电脑、MP4等与人们日常生活息息相关的电子设备。

那么，Android势不可当的魅力从何而来呢？本章将试着以Android系统的发展历史为主线，先为读者提供最直观的背景知识，从而为以后的“透过现象看本质”打下一定的基础。

1.1　Android系统发展历程

“Android”一词先天就充满着天才们改变世界的梦想味。虽然一件杰出的作品并不能只靠“名号”，但毋庸置疑的是，一个叫得响又耐人寻味的名称总会使人产生不自觉的亲近感。这或许就是每个Android版本都会有个代号的原因。下面来看看各个版本对应的Android“外号”，如表1-1所示。

表1-1　Android各版本的代号

Code name	Version	API level
(no code name)	1.0	API level 1
(no code name)	1.1	API level 2
Cupcake（纸杯蛋糕）	1.5	API level 3, NDK 1
Donut（甜甜圈）	1.6	API level 4, NDK 2
Éclair（松饼）	2.0	API level 5
Éclair	2.0.1	API level 6
Éclair	2.1	API level 7, NDK 3

Froyo（冻酸奶）	2.2.x	API level 8, NDK 4
Gingerbread（姜饼）	2.3 - 2.3.2	API level 9, NDK 5
Gingerbread	2.3.3 - 2.3.7	API level 10
Honeycomb（蜂巢）	3.0	API level 11
Honeycomb	3.1	API level 12, NDK 6
Honeycomb	3.2.x	API level 13
Ice-creamSandwich（冰激凌三明治）	4.0.1 - 4.0.2	API level 14, NDK 7
Ice-creamSandwich	4.0.3 - 4.0.4	API level 15
Jelly Bean（果冻豆）	4.1.x	API level 16
Jelly Bean	4.2.x	API level 17
Jelly Bean	4.3.x	API level 18

KitKat	4.4.x	API level 19
KitKat with wearable extensions	4.4W	API level 20
Lollipop	5.0.1	API level 21
Lollipop	5.1.1	API level 22
Marshmallow	6.0	API level 23
Nougat	7.0	API level 24
Nougat	7.1.1	API level 25

“Android”一词来源于法国作家Auguste Villiers de l'Isle-Adam的科幻小说《L'ève future》（未来夏娃），是机器人的意思。因此，最初每个系统版本的命名也都是以全球著名的机器人为参考的，如“AstroBoy”。后来由于版权问题，才改为以食物的方式取名。不过Android的Logo仍然是机器人的形象，如图1-1所示。

▲图1-1　Android官方Logo

和很多著名的科技企业一样，Android的创始人Andy Rubin也是一个技术狂人。在创立Android公司前，他曾完成多项当时被称为“过于超前”的产品研发，并取得了一定的成绩。而创办Android，最初的目的是提供一款开放式的移动平台系统。从2003年10月Andy Rubin开始启动这一系统的研究，Android便正式走上历史的舞台。以下是关于这个系统的一些重要历史事件。

- 2003年10月，Andy Rubin 在加利福尼亚州成立Android公司。
- 2005年4月，Google收购Android。
- 2007年11月，Google成立OHA（Open Handset Alliance）联盟，成员包括Google、Broadcom、HTC、Intel、LG、Marvell、Motorola、NVIDIA、Qualcomm、Samsung等通信行业和芯片制造领域的巨头。随后几年，这个联盟又陆续有不少公司加入，如著名的Arm公司、中国的华为等。
- 2007年11月，Google成立“Android Open Source Project”（AOSP）。这一项目的起步标志着Android系统首次公开面向全世界的开发者与使用者。

AOSP的宗旨是：

Android Open Source Project is to create a successful real-world product that improves the mobile experience for end users。

因为是开源开放的组织，所以意味着每个人都可以参与进来，并为整个项目的发展添砖加瓦。如果读者有意愿成为其中的一员，可以参考该组织的相关说明（http://source.android.com/source/index.html）。

- 2007年11月，Android Beta版本发布。
- 2007年11月，Android 第一个SDK版本发布。
- 2008年9月，Android 1.0版本正式发布。

至此，Android版本的发布驶入正常轨道，保持着每年多次升级的速度，并加入越来越多的创新功能。

关于Android每个版本的特性及改版后一些重要变化的详细说明，请参阅官方网站（http://source.android.com/source/overview.html）。相信经过仔细比对各个版本的变化，读者会发现Android系统确实一直在秉承其“为终端用户提供更好的移动设备体验”的宗旨。

1.2 Android系统特点

在这一节中，我们将从观察者的角度来客观评价Android系统某些突出的特点。这些分析中既包含了其值得肯定的诸多优点，也不吝指出其需要持续改善的地方。只有正确全面地了解一个系统所存在的优缺点，才可能在开发的过程中“知己知彼，百战不殆”，真正让系统为我们所用。

1. 开放与扩展性

相对于iOS和Windows Phone阵营，Android操作系统最大的特点就是开放性；而且有别于个别开源项目的“藏藏掖掖”和“犹抱琵琶半遮面”，Android几乎所有源码都可以免费下载到。无论是公司组织，还是个人开发者，Android对于下载者基本没有限制，也没有下载权限的认证束缚。关于如何下载系统源码的完整描述，请参考下一章节。

当然，这并不代表开发者可以随意使用Android源码。事实上，Android遵循的是Apache开源软件许可证。因此，所有跨越许可证规定范畴的行为都将是被禁止的。希望了解更多Apache协议条款详情的读者，可以自行查阅其官方说明（http://www.apache.org/）。

不过在大部分情况下，Android操作系统仍然被认为是“高度自由”的。这也是越来越多的厂商选择Android作为下一代产品基础平台最主要的原因之一。可以想象，在其他操作系统对其授权的设备动辄收取每台高达几十甚至数百美元专利费的情况下，采用Android开源系统理论上就意味着降低成本。

另外，由于整个操作系统是开源的，从而给诸多产品制造商、软件开发商提供了创新的土壤环境。各厂商可以根据自己的需求，来完成对原生态系统的修改。大多数情况下，这种修改只是基于上层UI交互的“二次包装”，而保留底层系统的大框架。这就好比Google为大家免费提供了已经盖好的办公大楼，虽然是毛坯房，但相较于“万丈高楼平地起”的艰辛，显然已经为我们节约了大量的项目时间；而且我们可以通过“装修”把主要精力倾注在用户看得到的地方，从而更大限度地摆脱“产品同质化”。事实上，目前全球范围内已经有非常多这样的“装修范例”。大到跨国企业、运营商，小到一些初创的设计公司，都选择在Android系统上进行“界面”改造，再冠以新的操作系统名号。其中

也不乏一些成功者，根据不同的地域环境、文化差异、使用习惯而定制出新的系统——这些具有“本地化”风格的“办公楼”往往比原生态系统更贴近当地消费者，因此受到热烈追捧。

而这一切，都要归功于Android系统的开放性。

2．合理的分层架构

要学习Android系统，就不得不提它的分层架构。早期版本的Android系统框架包括4层，即Linux Kernel、Library and Runtime、Application Framework及Application。后来因为版权相关原因在Kernel层之上新增了一个Hardware Abstraction Layer。我们会在后续小节对各层功能适当地展开讨论。

由此可见，Android系统是一个“杂合体”，即便说其“包罗万象”也一点不为过。它包括了prebuilt、bionic等在内的不少开源项目。管理这些项目显然不是件容易的事，这也是Android系统提供Repo工具，而不是直接使用Git来进行版本管理的原因之一（详见后续章节的描述）。

在面对这么多独立项目的时候，合理的分层架构就显得异常重要——既要保证系统功能的完整性，也要确保各项目的相对独立性。Android系统成功地做到了这一点，整个软件栈条理清晰，分工明确。一方面，它将底层复杂性与移植难度尽可能隐藏起来；另一方面，则提供尽可能方便的上层API接口，为开发者设计实现各种应用程序打下了坚实的基础。

3．易用强大的SDK

SDK（Software Development Kit）是操作系统与开发者之间的接口，也可以看成一个系统对外的窗口。对于广大的开发者而言，能否借助这个工具在尽可能短的周期内设计出符合需求而又稳定可靠的应用程序，是评判一个操作系统SDK好坏的重要标准之一。

Android系统的大部分应用程序可以基于Java来开发。如果读者曾参与过大型的C/C++研发项目（特别是面向嵌入式系统的），一定不会忘记加班加点解决内存泄露或者空指针异常的那些无眠夜。Java语言对这些软件开发中最令人头疼的问题进行了强有力的改造，不但提供了垃

圾回收机制，而且彻底隐藏了指针的使用。即便程序出现了崩溃，通常情况下也可以根据调用栈及各种Log来定位出问题的根源。这无疑为我们快速解决问题、保证程序稳定性提供了很好的平台基础。

Android系统通过总结应用程序的开发规律，提供了Activity、Service、Broadcast Receiver及Content Provider四大组件；并且和MFC类似，设计了人性化的向导模式来帮助开发者便捷地生成工程原型。可以说，这些都为项目开发节约了不少宝贵时间。

另外，Android SDK覆盖面相当广，且仍在持续扩充中。从线程管理、进程间通信等程序设计基础到各种界面组件的应用，只要是开发者能想到的，几乎都可以在SDK中找到现成的调用接口。而对一些界面特效的封装，使得开发者可以高效地设计出各种绚丽的UI效果，进而让Android系统加分良多。

4．不断改进的交互界面

Android版本的更迭是一件让无数人兴奋的事。除了那些令人眼前一亮的新功能外，不断改进的用户交互界面也是吸引用户的一个重要因素。我们可以明显地从新老版本的对比中寻找到Google追求绝佳用户体验的决心。

下面先来看看Gingerbread（2.3版本）的Launcher与Camera界面，如图1-2所示。

6:00
Google

▲图1-2　Launcher和Camera界面

然后来看看后续版本上的变化，如图1-3所示。

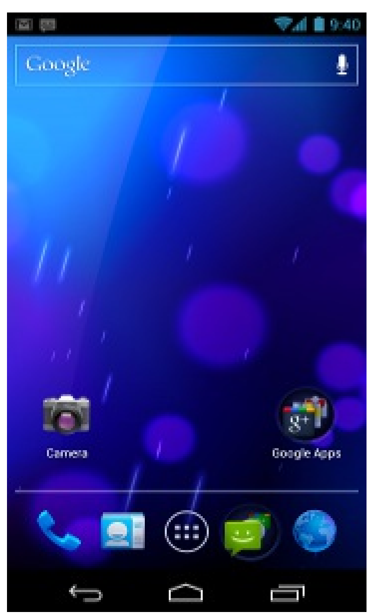

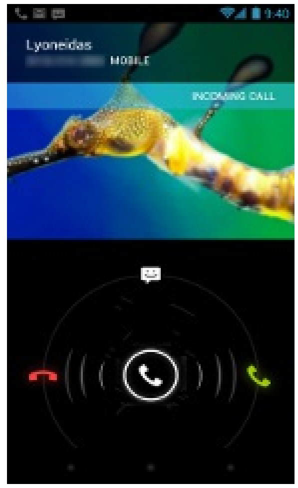

Lyoneidas
MOBILE
INCOMING CALL

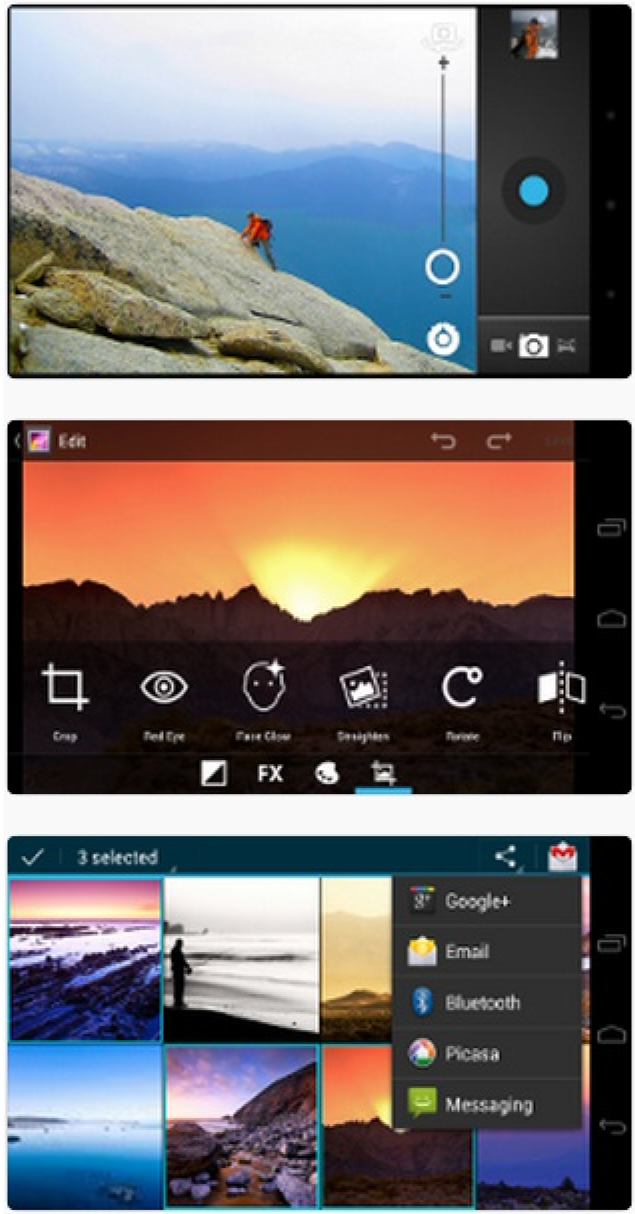

▲图1-3　后续Android版本变化

可以发现，新的版本相较于以前，不但在UI界面的色彩搭配、布局上有了很大提高，用户交互也更趋于人性化。这种对于用户最直观的“艺术盛宴”展示，促使越来越多的人投身到Android阵营中。

5．逐步完善的生态系统

IT业界长期以来都有一个共识——开发一个操作系统（OS）并不是最难的，而基于这个新的操作系统建立完整的生态系统才是最大的难

点。用一句老话来说，颇有点“打江山易，守江山难”的味道。

那么，什么是基于OS的生态系统（ecosystem）呢？虽然我们一再听到媒体在大肆宣扬这个词，但目前还没有人能给出权威、严谨的解释来阐述这个特殊“生态系统”的定义与形成。本书下面所提出的释义也未必能完整解读这个词，读者可以带着自己的理解深入思考。

Ecosystem原本是生态学中的一个概念。简单而言，它体现了一定时间和空间内能量的可循环平衡流动，例如，自然界的生态系统组成如下。

- 无机环境，包括太阳、有机物质、无机物质等非生物环境。
- 生产者。
- 消费者。
- 分解者。

因此，它们之间所体现出的能量循环如图1-4所示。

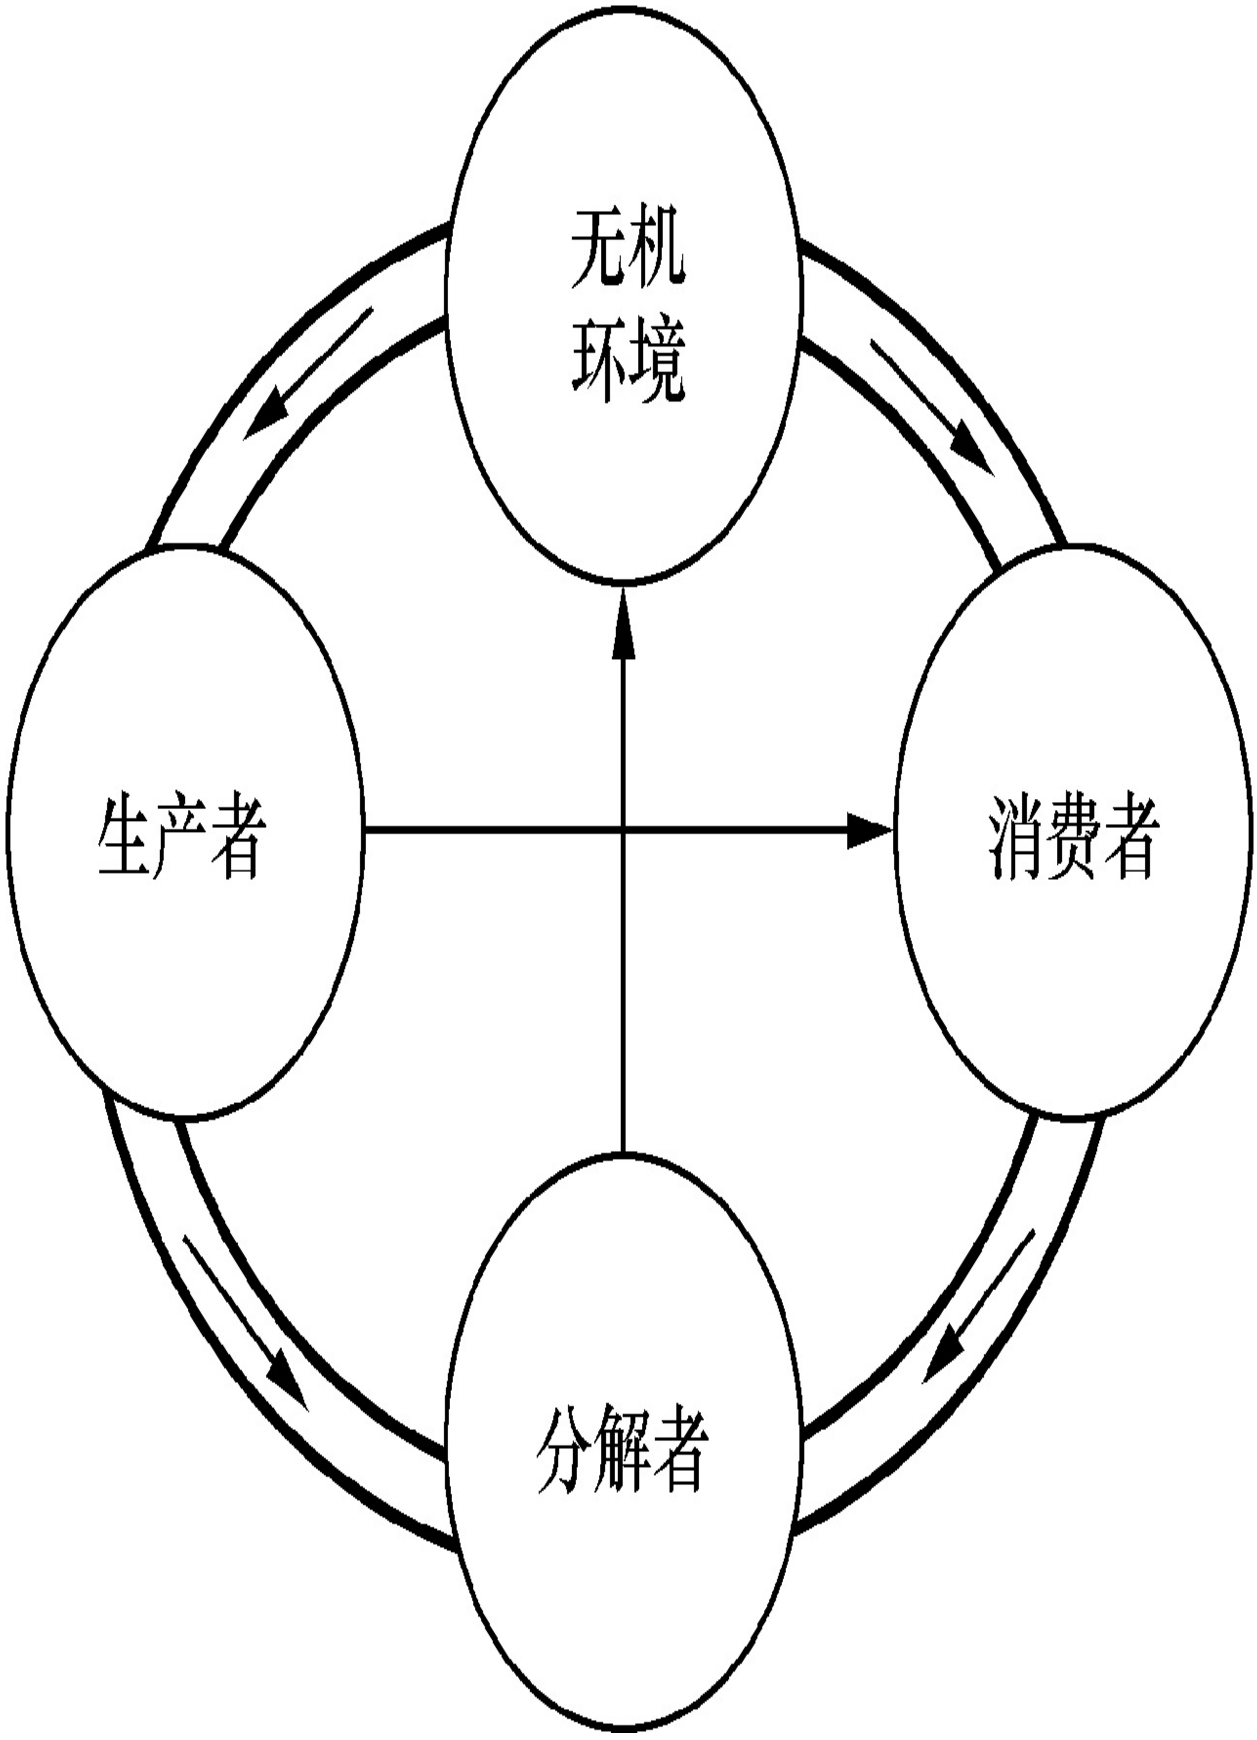
无机
环境
生产者
消费者
分解者

▲图1-4　自然生态系统的能量循环

生产者依靠无机环境制造食物，并实现自养；而消费者则需要消耗其他生物来生存发展；分解者最终将有机物分解为可被生产者重新利用的物质。这样，就构成了整个生态链的循环。

针对Android生态系统，我们可以得到以下的类比，如图1-5所示。

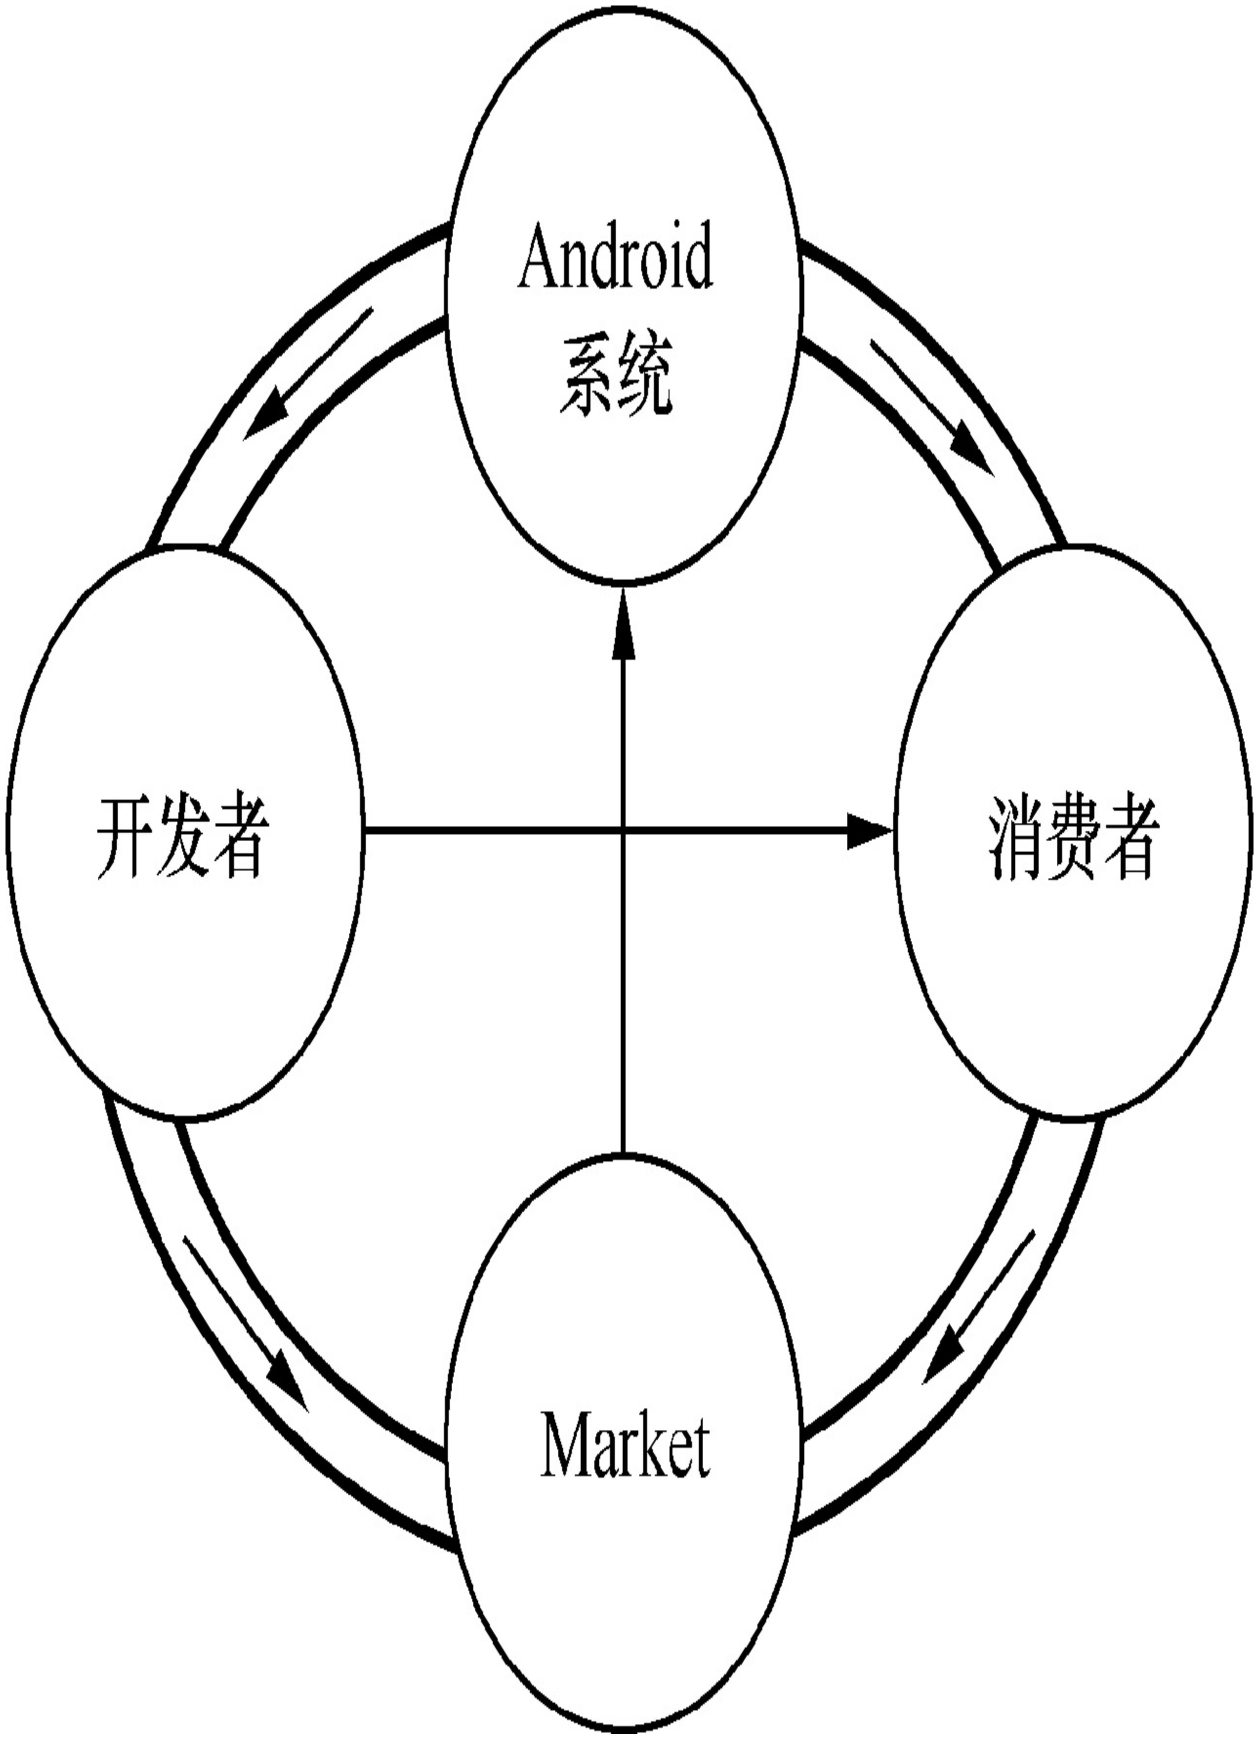
Android
系统
开发者
消费者
Market

▲图1-5 Android生态系统假想

在Android生态系统中：

- Android系统提供了底层基础平台；
- 开发者通过研发新产品来获取利润，或者提供相应服务；
- 消费者使用这些产品或服务来满足自身需求；
- Market提供了开发者与消费者间资金支付与交易的平台，加快了生物间的“能量”流动。

当然，这只是本书对Android生态系统的一个初步设想，实际情况一定更复杂。但客观来说，Google一方面既在努力打造“双赢”的市场机制，以吸引更多的开发者介入；另一方面也在提高为消费者服务的能力，如图1-6所示。

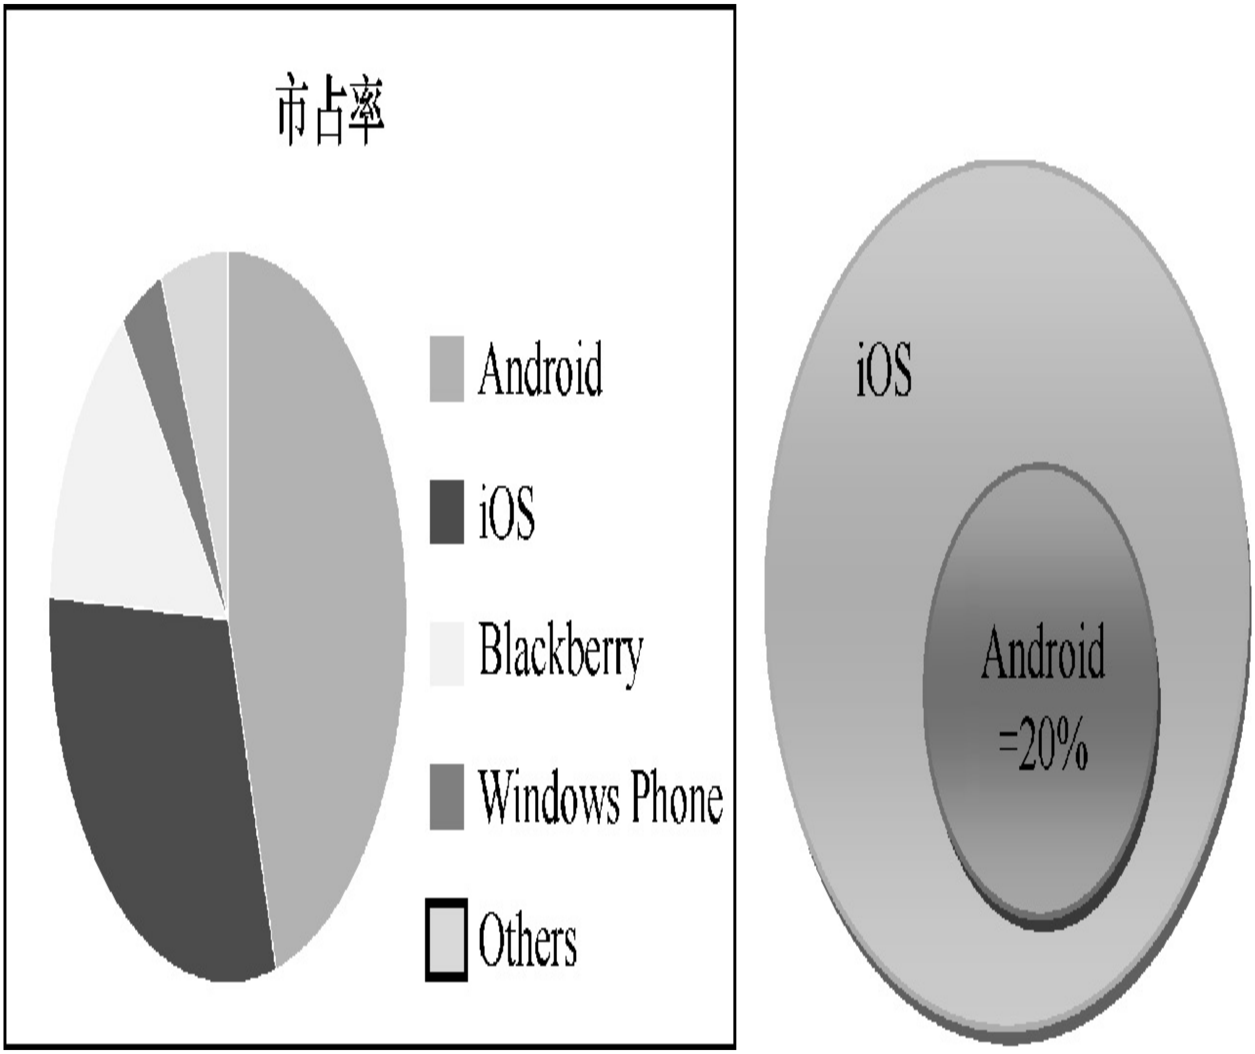

▲图1-6　各操作系统平台占有率及开发者赢利对比

虽然最新的调查报告显示，依靠Android软件赢利的开发者寥寥无几，还远远比不上iOS系统赢利模式成熟（见图1-6）。但同时也应该看到，随着整个Android市场占有率的提升以及Google一系列措施的实行，Android生态系统正在逐步完善，前景一片光明。

6．阵营良莠不齐

开源是一把“双刃剑”，它带来的一个突出问题就是阵营混乱。和一些操作系统需要收取高额的加盟费用不同，Android的免费开源大大降低了开发商的准入门槛。因此，出现了“人人都可以做手机”的局面。无论是资本、研发实力雄厚的大型企业，还是初出茅庐没有太多经验的小公司，都在不断进入这个生态圈。这既是Android系统的优势，

同时也是隐患。

因为每个厂商都可以根据自己的需求来改造原生态系统，从而难免造成整个Android阵营的分裂；而且，有的开发商也在努力基于Android建立自己的生态系统。这无疑会对Android的整体发展产生一定的影响。如果这些状况在今后一段时间里无法得到解决，那么很可能阻滞Android的进一步发展壮大。

7．系统运行速度有待改善

使用过Android相关产品的用户一定有这样的体验，那就是开机慢。一个针对目前市面上主流Android设备的不完全统计显示，Android产品的平均开机时间超过了1分钟，有的甚至达到5分钟以上。对于某些需要快速实时响应的电子设备而言（比如车载电子导航一体机，往往需要在汽车启动后非常短的时间内完成操作系统开机，以显示倒车影像），这样的“龟速”显然是很难让人接受的。

值得欣慰的是，Google也正致力于运行速度的改进。随着新版本的不断发布，我们已经可以明显地感受到Android在这方面所做的努力与成效。

8．兼容性问题

对于Android平台的应用开发者而言，最头疼的恐怕并不是某项创新功能的研发，而是对市面上多种设备的适配。在这方面，iOS的开发人员有绝对的优势，因为他们面对的往往只是一款机器（如iPhone6、iPhone7），而且屏幕尺寸、分辨率等系统属性也都是固定已知的，如图1-7所示。

Android系统由于开源、生产商众多，致使产品形态五花八门。以手机为例，为消费者所熟识的全球大型Android手机开发商就已经超过了20个。而这些厂商还有各自不同的产品型号——这也就意味着屏幕大小、分辨率等各种硬件参数的差异。按照目前行业的普遍经验，开发一款成熟的Android手机应用软件，需要适配200款以上不同厂商的手机，以保证软件发布后不至于出现大规模的用户投诉。如果是面向海外市场，则需要兼容的终端产品数量可能还会更多。

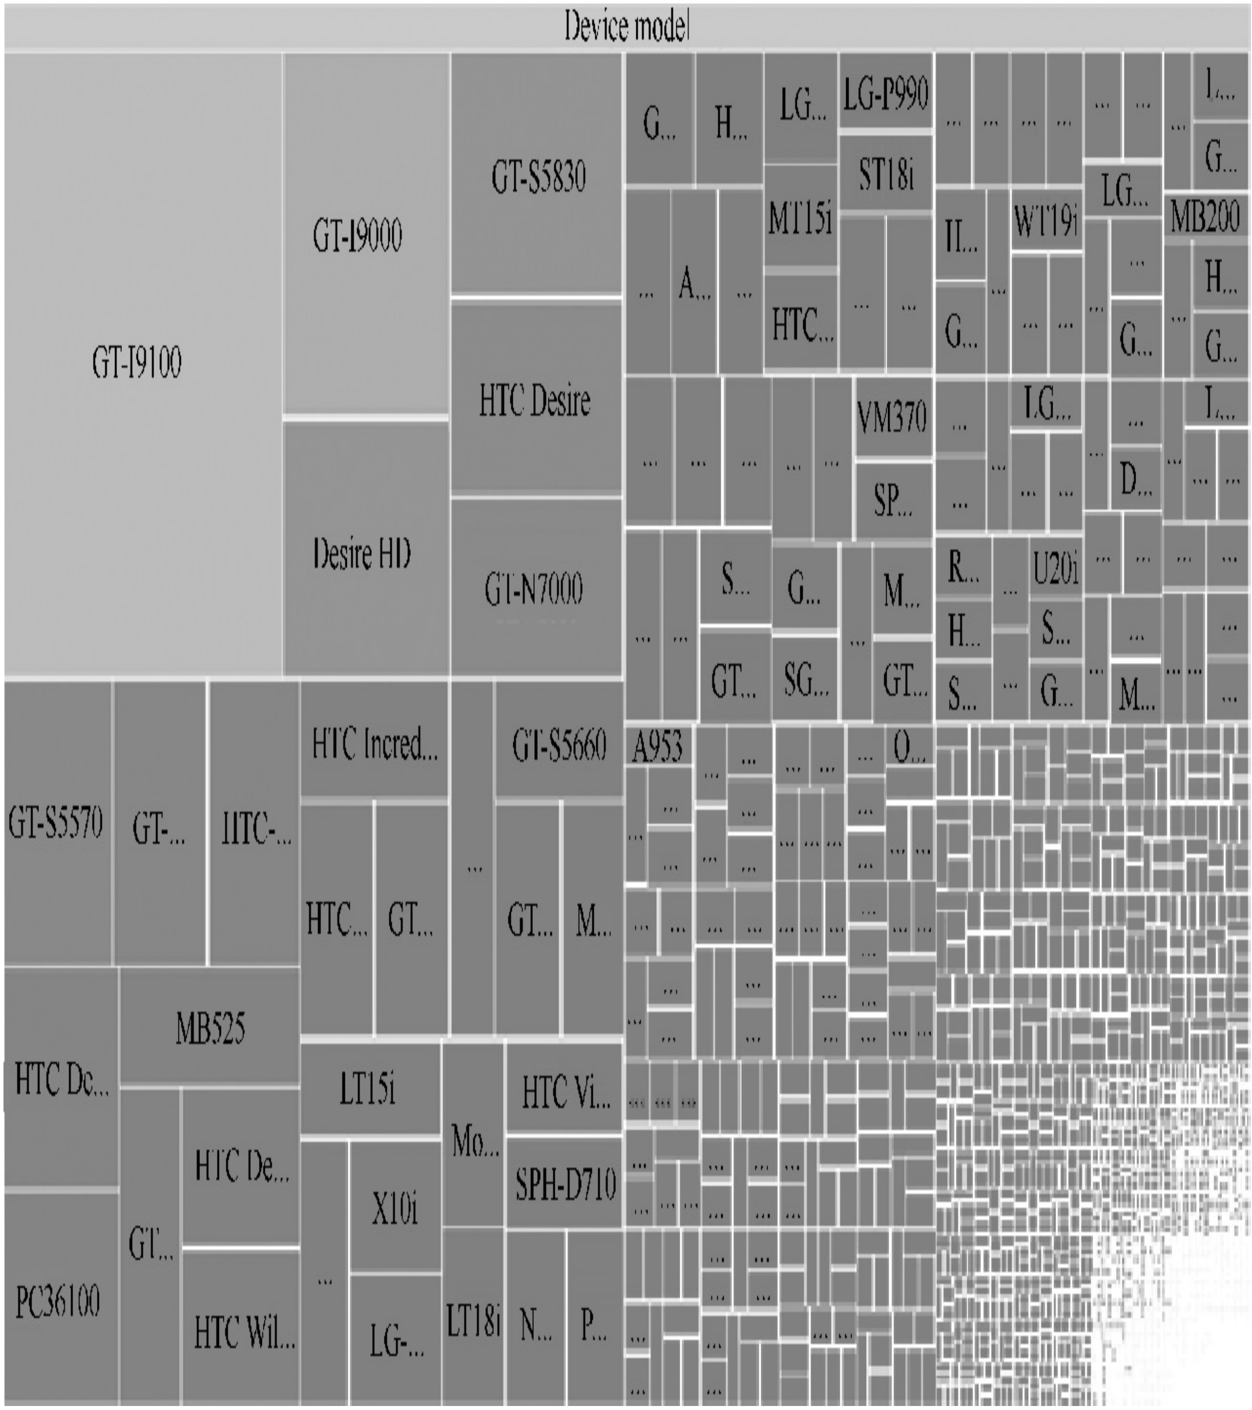

▲图1-7　OpenSignalMaps对市面上主流Android手机品牌的跟踪结果

虽然Android针对这一问题有一定的解决方法（详见本书应用原理篇的相关章节），但以实际开发经验来看，暂时还没有很好地解决难题的方法。

1.3 Android系统框架

Android系统框架如图1-8所示。

APPLICATIONS
Home
Dialer
SMS/MMS
IM
Browser
Camera
Alarm
Calculator
Contacts
Voice Dial
Email
Calendar
Media Player
Photo Album
Clock
...
APPLICATION FRAMEWORK
Activity Manager
Window Manager
Content Providers
View System
Notification Manager
Package Manager
Telephony Manager
Resource Manager
Location Manager
...
LIBRARIES
Surface Manager
Media Framework
SQLite
WebKit
Libc
OpenGL|ES
Audio Manager
FreeType
SSL
...
ANDROID RUNTIME
Core Libraries
Dalvik Virtual Machine
HARDWARE ABSTRACTION LAYER
Graphics
Audio
Camera
Bluetooth
GPS
Radio(RIL)
WiFi
...
LINUX KERNEL
Display Driver
Camera Driver
Bluetooth Driver
Shared Memory Driver
Binder(IPC) Driver
USB Driver
Keypad Driver
WiFi Driver
Audio Drivers
Power Management

▲图1-8　Android系统5层框架图

注意

引用自2008年的Google I/O大会《Anatomy & Physiology of an Android》主题演讲，作者Patrick Brady。

前面说过，Android系统是由众多子项目组成的。从编程语言的角度来看，这些项目主要是使用Java和C/C++来实现的；从整体系统框架而言，分成内核层、硬件抽象层、系统运行库层、应用程序框架层以及应用程序层。本书的一个主要宗旨是希望读者可以由浅入深地逐步理解Android系统的方方面面。因而在每章节内容的编排上，我们采用了由整体到局部的线索来铺展开——先让读者有一个直观感性的认识，明白“是什么”“有什么用”，然后才剖析“如何做到的”。这样做的一个好处是读者在学习的过程中不容易产生困惑。否则如果直接切入原理，长篇大论地分析代码，仅一大堆函数调用就可能让人失去学习的方向。这样的结果往往是读者花了非常多的时间来理清函数关系，但始终不明白代码编写者的意图，甚至连这些函数想实现什么功能都无法完全理解。

本书希望可以从更高的层次，即抽象的、反映代码设计思想和设计者初衷的角度去理解系统。而在思考的过程中，大部分情况下我们都将从读者容易理解的基础开始讲起。就好比画一张素描，先给出一张白纸，勾勒出整体的框架，然后针对重点部位细细加工，最后才能还原出完整的画面。另外，本书在对系统原理本身进行讲解的同时，也最大程度地结合工程项目中可能遇到的问题，理论联系实际地进行解析。希望这样的方式既能让读者真正学习到Android系统的设计思想，也能学有所用，增加一些实际的项目开发经验和技巧。

接下来的内容将对Android系统的5层框架做一个简单描述。

- 内核层

Android的底层是基于Linux操作系统的。从严格意义上来讲，它属于Linux操作系统的一个变种。Android选择在Linux内核的基础上来搭

建自己的运行平台有几个好处。

首先，避开了与硬件直接打交道。Linux经过多年的发展，这方面工作正是它的强项，其表现可以说相当优秀。更为难能可贵的是，Linux本身也是开源的，所以Android系统没有必要花费额外的时间去做重复工作。

其次，基于Linux系统的驱动开发可扩展性很强。这对于嵌入式系统而言非常重要，因为每款产品在硬件上或多或少都会有差异，如果驱动开发不能做到高度可扩展和易用性，那么Android系统的移植工作将是无止境的噩梦。

值得一提的是，Android的工程项目中并没有包括内核源码——内核源码的具体下载方式可以参见下一章节。

- 硬件抽象层

大家可能都有这样的疑问，既然Linux内核是专职与硬件打交道的，为什么又杀出个“程咬金”硬件抽象层（HAL）呢？没错，这个“人物”一开始并没有出现在Android的“剧本”中，其出场是有一定历史原因的。

HAL的第一次亮相要追溯到2008年的Google I/O大会上。当时Google员工Patrick Brady发表了一篇名为《Anatomy & Physiology of an Android》的演讲，并在其中提出了带HAL的Android新架构。根据这份文档的描述，HAL是：

（1）User space C/C++ library layer；

（2）Defines the interface that Android requires hardware “drivers” to implement；

（3）Separates the Android platform logic from the hardware interface。

也就是说，它希望通过定义硬件“驱动”的接口来进一步降低Android系统与硬件的耦合度。另外，由于Linux遵循的是GPL协议（注意，Android开源项目基于Apache协议），意味着其下的所有驱动都应

该是开源的——这点对于部分厂商来说是无法接受的。因而，Android提供了一种“打擦边球”的做法来规避这类问题。我们会在后续章节中继续讲解关于HAL的更多知识。

- 系统运行库层

　　这一层中包含了支撑整个系统正常运行的基础库。由于这些库多数由C/C++实现，因此也被一些开发人员称为“C库层”，以区别于应用程序框架层。Android中很多系统运行库实际上都是成熟的开源项目，如WebKit、OpenGL、SQLite等。我们并不要求读者去理解所有库的内部原理，这样做不现实。重点在于Android系统是如何有机地与这些库建立联系，从而保证整个设备的稳定运作的。

- 应用程序框架层

　　与系统运行库被称为“C库层”相对应，应用程序框架层往往被冠以“Java库”的称号。这是因为框架层所提供的组件一般都用Java语言编写而成，它们一方面为上层应用程序提供了API接口；另一方面也囊括了不少系统级服务进程的实现，是与Android应用程序开发者关系最直接的一层。

- 应用程序层

　　目前Android的软件开发分为两个方向，即系统移植与应用程序的开发。

　　对于一名出色的应用程序员而言，不仅要了解该使用哪些系统API接口去完成一个功能，还要尽可能了解这些接口及其下的系统底层框架是如何实现的。虽然理解系统运行原理对于应用开发者来说并不是必需的，但在很多情况下却可以极大地提高程序员分析问题的能力，也可在产品性能优化方面产生积极的作用。

第2章 Android源码下载及编译

在分析Android源码前，首先要学会如何下载和编译系统。本章将向读者完整地呈现Android源码的下载流程、常见问题以及处理方法，并从开发者的角度来理解如何正确地编译出Android系统（包括原生态系统和定制设备）。

后面，我们将在此基础上深入到编译脚本的分析中，以“庖丁解牛”的方式来还原一个庞大而严谨的Android编译系统。

2.1 Android源码下载指南

2.1.1 基于Repo和Git的版本管理

Git是一种分布式的版本管理系统，最初被设计用于Linux内核的版本控制。本书工具篇中对Git的使用方法、原理框架有比较详细的剖析，建议读者先到相关章节阅读了解。

Git的功能非常强大，速度也很快，是当前很多开源项目的首选工具。不过Git也存在一定的缺点，如相对于图形界面化的工具没那么容易上手、需要对内部原理有一定的了解才能很好地运用、不支持断点续传等。

为此，Google提供了一个专门用于下载Android系统源码的Python脚本，即Repo。

在Repo环境下，版本修改与提交流程是：

- 用Repo创建新的分支，通常情况下不建议在master分支上操作；
- 开发者根据需求对项目文件进行修改；
- 利用git add命令将所做修改进行暂存；
- 利用git commit命令将修改提交到仓库；
- 利用repo upload命令将修改提交到代码服务器上。

由此可见，Repo与我们在工具篇中讨论的Git流程有些许不同，差异主要体现在与远程服务仓库的交互上；而本地的开发仍然是以原生的Git命令为主。下面我们讲解Repo的一些常用命令，读者也可以拿它和Git进行仔细比较。

1. 同步

同步操作可以让本地代码与远程仓库保持一致。它有两种形式。

如果是同步当前所有的项目：

```
$ repo sync
```

或者也可以指定需要同步的某个项目：

```
$ repo sync [PROJECT1] [PROJECT2]…
```

2. 分支操作

创建一个分支所需的命令：

```
$ repo start <BRANCH_NAME>
```

也可以查看当前有多少分支：

```
$ repo branches
```

或者：

```
$ git branch
```

以及切换到指定分支：

```
$ git checkout <BRANCH_NAME>
```

3. 查询操作

查询当前状态：

```
$ repo status
```

查询未提交的修改：

```
$ repo diff
```

4. 版本管理操作

暂存文件：

```
$git add
```

提交文件：

```
$git commit
```

如果是提交修改到服务器上，首先需要同步一下：

```
$repo sync
```

然后执行上传指令：

```
$repo upload
```

2.1.2 Android源码下载流程

了解了Repo的一些常规操作后，这一小节接着分析Android源码下载的全过程。这既是剖析Android系统原理的前提，也是让很多新手感到困惑的地方——源码下载可以作为初学者了解Android系统的“Hello World”。

值得一提的是，Android官方建议我们务必确保编译系统环境符合以下几点要求：

- Linux或者Mac系统

在虚拟机上或是其他不支持的系统（例如Windows）上编译Android系统也是可能的，事实上Google鼓励大家去尝试不同的操作系统平台。不过Google内部针对Android系统的编译和测试工作大多是在Ubuntu LTS(14.04)上进行的。因而建议开发人员也都选择同样的操作系统版本来开展工作，经验告诉我们这样可以少走很多弯路。

如果是在虚拟机上运行的Linux系统，那么理论上至少需要16GB的RAM/Swap才有可能完成整个Android系统的编译。

- 对于Gingerbread(2.3.X)及以上的版本，64位的开发环境是必需的。其他旧的Android系统版本可以采用32位的开发环境。
- 需要至少100GB以上的磁盘空间才能完成系统的一系列编译过程——仅源码大小就已经将近10GB了。
- Python 2.6-2.7，开发人员可以从Python官网上下载：www.python.org。
- GNU Make 3.81-3.82，开发人员可以从Gnu官网上下载：www.gnu.org。

- 如果是编译最新版本的Android N系统，那么需要Java8(OpenJDK)。后续编译章节我们还会专门介绍。
- Git 1.7以上版本，开发人员可以从Git官网上下载：http://git-scm.com。

要特别提醒大家的是，以下所有步骤都是在Ubuntu操作系统中完成的（“#”号后面表示注释内容）。

1. 下载Repo

```
$ cd ～  #进入home目录
$ mkdir bin #创建bin目录用于存放Repo脚本
$ PATH=～/bin:$PATH #将bin目录加入系统路径中
$ curl https://storage.googleapis.com/git-repo-downloads/repo > ~
#是一个基于命令行的文件传输工具，它支持非常多的协议。这里我们利用curl来将repo
$ chmod a+x ～/bin/repo
```

注：网上有很多开发者（中国大陆地区）反映上面的地址经常无法成功访问。如果读者也有类似困扰，可以试试下面这个：

```
$curl http://android.googlesource.com/repo > ～/bin/repo
```

另外，国内不少组织（特别是教育机构）也对Android做了镜像，如清华大学提供的开源项目（TUNA）的mirror地址如下：

```
https://aosp.tuna.tsinghua.edu.cn/
```

下面是TUNA官方对Android代码库的使用帮助节选：

```
Android镜像使用帮助
参考Google教程https://source.android.com/source/downloading.html，将
本站资源有限，每个IP限制并发数为4，请勿使用repo sync-j8这样的方式同步。
替换已有的AOSP源代码的remote。
如果你之前已经通过某种途径获得了AOSP的源码（或者你只是init这一步完成后），你

<manifest>
   <remote  name="aosp"
-           fetch="https://android.googlesource.com"
+           fetch="git://aosp.tuna.tsinghua.edu.cn/android/"
            review="android-review.googlesource.com" />
   <remote  name="github"
这个方法也可以用来在同步Cyanogenmod代码的时候从TUNA同步部分代码
```

下载repo后，最好进行一下校验，各版本的校验码如下所示：

```
对于 版本 1.17, SHA-1 checksum是：ddd79b6d5a7807e911b524cb223bc3544
对于 版本 1.19, SHA-1 checksum是：92cbad8c880f697b58ed83e348d06619f
对于 版本 1.20, SHA-1 checksum 是：e197cb48ff4ddda4d11f23940d316e32
对于 版本 1.21, SHA-1 checksum 是：b8bd1804f432ecf1bab730949c82b93b
```

2．Repo配置

在开始下载源码前，需要对Repo进行必要的配置。

如下所示：

```
$ mkdir source #用于存放整个项目源码
$ cd source
$ repo init -u https://android.googlesource.com/platform/manifest
############以下为注释部分########
init命令用于初始化repo并得到近期的版本更新信息。如果你想获取某个非master分支
$ repo init -u https://android.googlesource.com/platform/manifest
完成配置后，repo会有如下提示：
repo initialized in /home/android
这时在你的机器home目录下会有一个.repo目录，用于记录manifest等信息########
######
```

3．下载源码

完成初始化动作后，就可以开始下载源码了。根据上一步的配置，下载到的可能是最新版本或者某分支版本的系统源码。

```
$ repo sync
```

由于整个Android源码项目非常大，再加上网络等不确定因素，运气好的话可能1～2个小时就能品尝到“Android盛宴”；运气不好的话，估计一个礼拜也未必能完成这一步——如果下载一直失败的话，读者也可以尝试到网上搜索别人已经下载完成的源码包，因为通常在新版本发布后的第一时间就有热心人把它上传到网上了。

可以看到在Repo的帮助下，整个下载过程还是相当简单直观的。

提示：如果你在下载过程中出现暂时性的问题（如下载意外中断），可以多试几次。如果一直存在问题，则很可能是代理、网关等原因造成的。更多常见问题的描述与解决方法，可以参见下面这个网址。

http://source.android.com/source/known-issues.html

典型的repo下载界面如图2-1所示。

```
* [new tag]         android-cts-4.4_r1 -> android-cts-4.4_r1
* [new tag]         android-cts-5.1_r1 -> android-cts-5.1_r1
* [new tag]         android-cts-verifier-4.0.3_r1 -> android-cts-verifier-4.0.3_r1
* [new tag]         android-cts-verifier-4.0_r1 -> android-cts-verifier-4.0_r1
* [new tag]         android-l-preview_r2 -> android-l-preview_r2
* [new tag]         android-sdk-4.0.3-tools_r1 -> android-sdk-4.0.3-tools_r1
* [new tag]         android-sdk-4.0.3_r1 -> android-sdk-4.0.3_r1
* [new tag]         android-sdk-4.4.2_r1 -> android-sdk-4.4.2_r1
* [new tag]         android-sdk-4.4.2_r1.0.1 -> android-sdk-4.4.2_r1.0.1
* [new tag]         android-sdk-adt_r16.0.1 -> android-sdk-adt_r16.0.1
* [new tag]         android-sdk-adt_r20 -> android-sdk-adt_r20
* [new tag]         android-sdk-support_r11 -> android-sdk-support_r11
* [new tag]         android-wear-5.0.0_r1 -> android-wear-5.0.0_r1
Fetching project device/samsung/manta
  % Total    % Received % Xferd  Average Speed   Time    Time     Time  Current
                                 Dload  Upload   Total   Spent    Left  Speed
100     1  100     1    0     0      1      0  0:00:01 --:--:--  0:00:01     19-k - -- :--: --
 49  428M     0 134990M     212 0 M 159  3k  0      0     0   0     25319k0k           00
    0 34954  5k 42  8M 0      4  09     21354M1k         0  0    1  :070 :2  8  250:09k0:  10
```

▲图2-1　原生Android工程的典型下载界面

Android系统本身是由非常多的子项目组成的，这也是为什么我们需要repo来统一管理AOSP源码的一个重要原因，如图2-2所示（部分）。

platform/external/alsa-lib

platform/external/android-clat

platform/external/android-cmake

platform/external/android-mock

platform/external/androidplot

platform/external/angle

platform/external/AntennaPod/afollestad b/27076782

platform/external/AntennaPod/AntennaPod b/27076782

platform/external/AntennaPod/AudioPlayer b/27076782

platform/external/ant-glob

▲图2-2 子项目

另外，不同子项目之间的branches和tags的区别如图2-3所示。

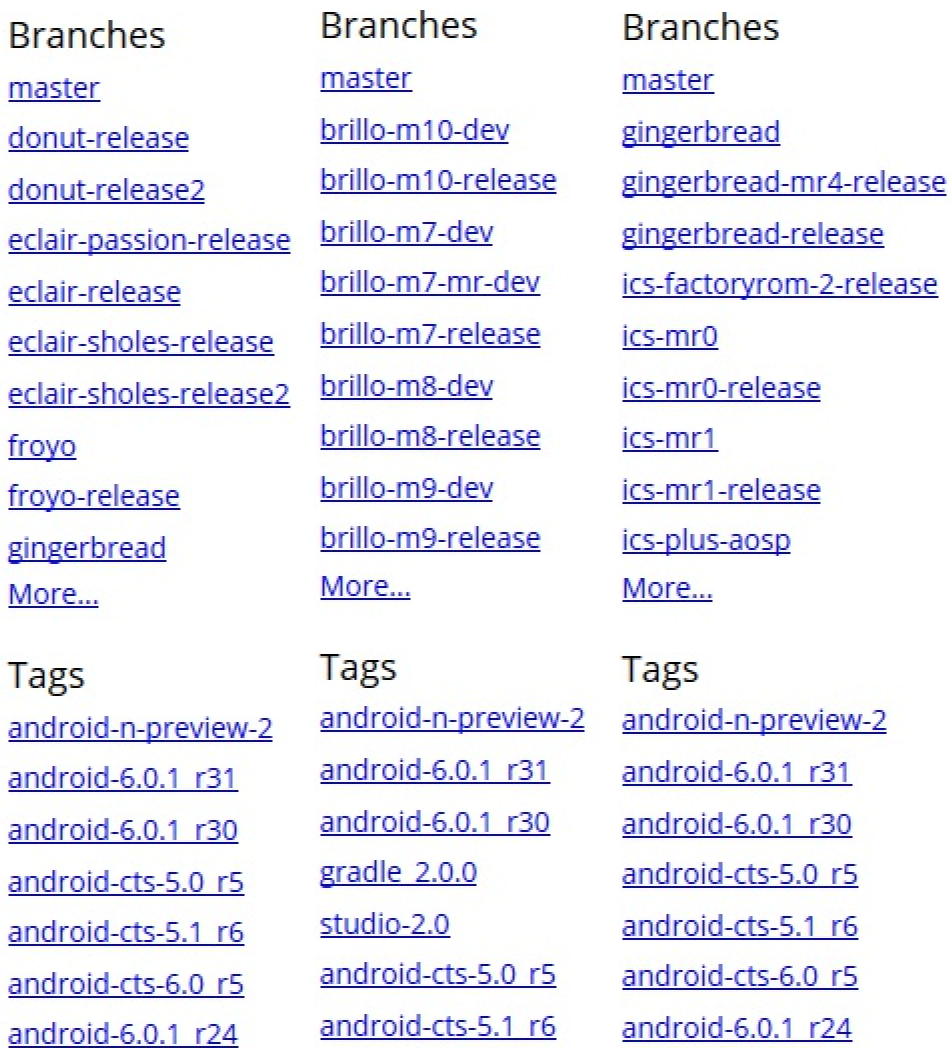

▲图2-3　Android各子项目的分支和标签
（左：frameworks/base，中：frameworks/native，右：/platform/libcore）

当我们使用repo init命令初始化AOSP工程时，会在当前目录下生成一个repo文件夹，如图2-4所示。

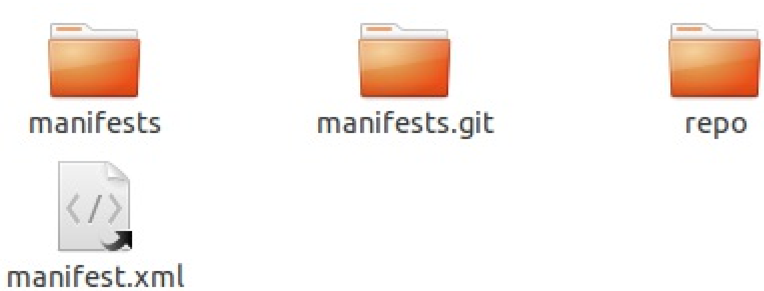

▲图2-4 repo文件

其中manifests本身也是一个Git项目，它提供的唯一文件名为default.xml，用于管理AOSP中的所有子项目（每个子项目都由一个project标签表示）：

```
<project path="art" name="platform/art" groups="pdk" />
<project path="bionic" name="platform/bionic" groups="pdk" />
<project path="bootable/recovery" name="platform/bootable/recovery" groups="pdk" />
<project path="cts" name="platform/cts" groups="cts,pdk-cw-fs,pdk-fs" />
```

另外，default.xml中记录了我们在初始化时通过-b选项指定的分支版本，例如“android-n-preview-2”：

```
<default revision="refs/tags/android-n-preview-2"
         remote="aosp"
         sync-j="4" />
```

这样当执行repo sync命令时，系统就可以根据我们的要求去获取正确的源码版本了。

友情提示：经常有读者询问阅读Android源码可以使用哪些工具。除了著名的Source Insight外，另外还有一个名为SlickEdit的IDE也是相当不错的（支持Windows、Linux和Mac），建议大家可以对比选择最适合自己的工具。

2.2 原生Android系统编译指南

任何一个项目在编译前，都首先需要搭建一个完整的编译环境。Android系统通常是运行于类似Arm这样的嵌入式平台上，所以很可能涉及交叉编译。

什么是交叉编译呢？

简单来说，如果目标平台没有办法安装编译器，或者由于资源有限等无法完成正常的编译过程，那就需要另一个平台来辅助生成可执行文件。如很多情况下我们是在PC平台上进行Android系统的研发工作，这时就需要通过交叉编译器来生成可运行于Arm平台上的系统包。需要特别提出的是，“平台”这个概念是指硬件平台和操作系统环境的综合。

交叉编译主要包含以下几个对象。

宿主机（Host）：指的是我们开发和编译代码所在的平台。目前不少公司的开发平台都是基于X86架构的PC，操作系统环境以Windows和Linux为主。

目标机（Target）：相对于宿主机的就是目标机。这是编译生成的系统包的目标平台。

交叉编译器（Cross Compiler）：本身运行于宿主机上，用于产生目标机可执行文件的编译器。

针对具体的项目需求，可以自行配置不同的交叉编译器。不过我们建议开发者尽可能直接采用国际权威组织推荐的经典交叉编译器。因为它们在release之前就已经在多个项目上测试过，可以为接下来的产品开发节约宝贵的时间。表2-1所示给出了一些常见的交叉编译器及它们的应用环境。

表2-1　常用交叉编译器及应用环境

交叉编译器	宿　主　机	目　标　机

armcc	X86PC(windows)，ADS开发环境	Arm
arm-elf-gcc	X86PC(windows)，Cygwin开发环境	Arm
arm-linux-gcc	X86PC(Linux)	Arm

2.2.1　建立编译环境

本书所采用的宿主机是X86PC（Linux），通过表2-1可知在编译过程中需要用到arm-linux-gcc交叉编译器（注：Android系统工程中自带了交叉编译工具，只要在编译时做好相应的配置即可）。

接下来我们分步骤来搭建完整的编译环境，并完成必要的配置。所选取的宿主机操作系统是Ubuntu的14.04版本LTS（这也是Android官方推荐的）。为了不至于在编译过程中出现各种意想不到的问题，建议大家也采用同样的操作系统环境来执行编译过程。

Step1. 通用工具的安装

表2-2给出了所有需要安装的通用工具及它们的下载地址。

表2-2　通用编译工具的安装及下载地址

<table>
<tr><td colspan="2">通 用 工 具</td><td>安装地址、指南</td></tr>
<tr><td colspan="2">Python 2.X</td><td>http://www.python.org/download/</td></tr>
<tr><td colspan="2">GNU Make 3.81 -- 3.82</td><td>http://ftp.gnu.org/gnu/make/</td></tr>
<tr><td rowspan="2">JDK</td><td>Java 87 针对Kitkat以上版本</td><td>最新的Android工程已经改用OpenJDK，并要求为Java 87及以上版本。这点大家应该特别注意，否则可能在编译过程中遇到各种问题。具体安装方式见下面的描述</td></tr>
<tr><td>JDK 6 针对Gingerbread到Kitkat之</td><td></td></tr>
</table>

	间的版本	http://java.sun.com/javase/downloads/
	JDK 5 针对Cupcake到Froyo之间版本	
Git 1.7以上版本		http://git-scm.com/download

对于开发人员来说，他们习惯于通过以下方法安装JDK（如果处于Ubuntu系统下）：

Java 6：

```
$ sudo add-apt-repository "deb http://archive.canonical.com/ luci
$ sudo apt-get update
$ sudo apt-get install sun-java6-jdk
```

Java 5：

```
$ sudo add-apt-repository "deb http://archive.ubuntu.com/ubuntu h
$sudo add-apt-repository "deb http://archive.ubuntu.com/ubuntu ha
multiverse"
$ sudo apt-get update
$ sudo apt-get install sun-java5-jdk
```

但是随着Java的版本变迁及Sun（已被Oracle收购）公司态度的转变，目前获取Java的方式也发生了很大变化。基于版权方面的考虑（大家应该已经听说了Oracle和Google之间的官司恩怨），Android系统已经将Java环境切换到了OpenJDK，安装步骤如下所示：

```
$ sudo apt-get update
$ sudo apt-get install openjdk-8-jdk
```

首先通过上述命令install OpenJDK 8，成功后再进行如下配置：

```
$ sudo update-alternatives --config java
$ sudo update-alternatives --config javac
```

如果出现Java版本错误的问题，make系统会有如下提示：

```
************************************************************
You are attempting to build with the incorrect version
```

```
of java.

Your version is: WRONG_VERSION.
The correct version is: RIGHT_VERSION.

Please follow the machine setup instructions at
    https://source.android.com/source/download.html
************************************************************
```

Step2. Ubuntu下特定工具的安装

注意，这一步中描述的安装过程是针对Ubuntu而言的。如果你是在其他操作系统下执行的编译，请参阅官方文档进行正确配置；如果你是在虚拟机上运行的Ubuntu系统，那么请至少保留16GB的RAM/SWAP和100GB以上的磁盘空间，这是完成编译的基本要求。

- Ubuntu 14.04

```
    $ sudo apt-get install bison g++-multilib git gperf libxml2-u
dev:i386 zip
```

- Ubuntu 12.04

所需的命令如下：

```
    $ sudo apt-get install git gnupg flex bison gperf build-essen
    zip curl libc6-dev libncurses5-dev:i386 x11proto-core-dev \
    libx11-dev:i386 libreadline6-dev:i386 libgl1-mesa-glx:i386 \
    libgl1-mesa-dev g++-multilib mingw32 tofrodos \
    python-markdown libxml2-utils xsltproc zlib1g-dev:i386
$ sudo ln -s /usr/lib/i386-linux-gnu/mesa/libGL.so.1 /usr/lib/i38
```

- Ubuntu 10.04 - 11.10

需要安装的程序比较多，不过我们还是可以通过apt-get来轻松完成。

具体命令如下：

```
$ sudo apt-get install git-core gnupg flex bison gperf build-esse
  zip curl zlib1g-dev libc6-dev lib32ncurses5-dev ia32-libs \
  x11proto-core-dev libx11-dev lib32readline5-dev lib32z-dev \
```

```
  libgl1-mesa-dev g++-multilib mingw32 tofrodos python-markdown \
  libxml2-utils xsltproc
```

注意，如果以上命令中存在某些包找不到的情况，可以试试以下命令：

```
$ sudo apt-get install git-core gnupg flex bison gperf libsdl-dev
```

如果你的操作系统刚好是Ubuntu 10.10，那么还需要：

```
$ sudo ln -s /usr/lib32/mesa/libGL.so.1 /usr/lib32/mesa/libGL.so
```

如果你的操作系统刚好是Ubuntu 11.10，那么还需要：

```
$ sudo apt-get install libx11-dev:i386
```

Step3. 设立ccache（可选）

如果你经常执行“make clean”，或者需要经常编译不同的产品类别，那么ccache还是有用的。它可以作为编译时的缓冲，从而加快重新编译的速度。

首先，需要在.bashrc中加入如下命令。

```
export USE_CCACHE=1
```

如果你的home目录是非本地的文件系统（如NFS），那么需要特别指定（默认情况下它存放于～/.ccache）：

```
export CCACHE_DIR=<path-to-your-cache-directory>
```

在源码下载完成后，必须在源码中找到如下路径并执行命令：

```
prebuilt/linux-x86/ccache/ccache -M 50G
#推荐的值为50-100GB，你可以根据实际情况进行设置
```

Step4. 配置USB访问权限

USB的访问权限在我们对实际设备进行操作时是必不可少的（如下载系统程序包到设备上）。在Ubuntu系统中，这一权限通常需要特别的配置才能获得。

可以通过修改/etc/udev/rules.d/51-android.rules来达到目的。

例如，在这个文件中加入以下命令内容：

```
# adb protocol on passion (Nexus One)
SUBSYSTEM=="usb", ATTR{idVendor}=="18d1", ATTR{idProduct}=="4e12"
="<username>"
# fastboot protocol on passion (Nexus One)
SUBSYSTEM=="usb", ATTR{idVendor}=="0bb4", ATTR{idProduct}=="0fff"
="<username>"
# adb protocol on crespo/crespo4g (Nexus S)
SUBSYSTEM=="usb", ATTR{idVendor}=="18d1", ATTR{idProduct}=="4e22"
="<username>"
# fastboot protocol on crespo/crespo4g (Nexus S)
SUBSYSTEM=="usb", ATTR{idVendor}=="18d1", ATTR{idProduct}=="4e20"
="<username>"
# adb protocol on stingray/wingray (Xoom)
SUBSYSTEM=="usb", ATTR{idVendor}=="22b8", ATTR{idProduct}=="70a9"
="<username>"
# fastboot protocol on stingray/wingray (Xoom)
SUBSYSTEM=="usb", ATTR{idVendor}=="18d1", ATTR{idProduct}=="708c"
="<username>"
# adb protocol on maguro/toro (Galaxy Nexus)
SUBSYSTEM=="usb", ATTR{idVendor}=="04e8", ATTR{idProduct}=="6860"
="<username>"
# fastboot protocol on maguro/toro (Galaxy Nexus)
SUBSYSTEM=="usb", ATTR{idVendor}=="18d1", ATTR{idProduct}=="4e30"
="<username>"
# adb protocol on panda (PandaBoard)
SUBSYSTEM=="usb", ATTR{idVendor}=="0451", ATTR{idProduct}=="d101"
="<username>"
# fastboot protocol on panda (PandaBoard)
SUBSYSTEM=="usb", ATTR{idVendor}=="0451", ATTR{idProduct}=="d022"
="<username>"
# usbboot protocol on panda (PandaBoard)
SUBSYSTEM=="usb", ATTR{idVendor}=="0451", ATTR{idProduct}=="d00f"
="<username>"
# usbboot protocol on panda (PandaBoard ES)
SUBSYSTEM=="usb", ATTR{idVendor}=="0451", ATTR{idProduct}=="d010"
="<username>"
```

如果严格按照上述4个步骤来执行，并且没有任何错误——那么恭喜你，一个完整的Android编译环境已经搭建完成了。

2.2.2 编译流程

上一小节我们建立了完整的编译环境，可谓“万事俱备，只欠东风”，现在就可以执行真正的编译操作了。

下面内容仍然采用分步的形式进行讲解。

Step1. 执行envsetup脚本

脚本文件envsetup.sh记录着编译过程中所需的各种函数实现，如lunch、m、mm等。你可以根据需求进行一定的修改，然后执行以下命令：

```
$ source ./build/envsetup.sh
```

也可以用点号代替source：

```
$ . ./build/envsetup.sh
```

Step2. 选择编译目标

编译目标由两部分组成，即BUILD和BUILDTYPE。表2-3和表2-4给出了详细的解释。

表2-3　BUILD参数详解

BUILD	设备	备　注
Full	模拟器	全编译，即包括所有的语言、应用程序、输入法等
full_maguro	maguro	全编译，并且运行于 Galaxy Nexus GSM/HSPA+ ("maguro")
full_panda	panda	全编译，并且运行于 PandaBoard ("panda")

可见BUILD可用于描述不同的目标设备。

表2-4　BUILDTYPE参数详解

BUILDTYPE	备　注
User	编译出的系统有一定的权限限制，通常用来发布最终的上市版本
userdebug	编译出的系统拥有root权限，通常用于调试目的
Eng	即engineering版本

可见BUILDTYPE可用于描述各种不同的编译场景。

选择不同的编译目标，可以使用以下命令：

```
$ lunch BUILD-BUILDTYPE
```

如我们执行命令“lunch full-eng”，就相当于编译生成一个用于工程开发目的，且运行于模拟器的系统。

如果不知道有哪些产品类型可选，也可以只敲入“lunch”命令，这时会有一个列表显示出当前工程中已经配置过的所有产品类型（后续小节会讲解如何添加一款新产品）；然后可以根据提示进行选择，如图2-5所示。

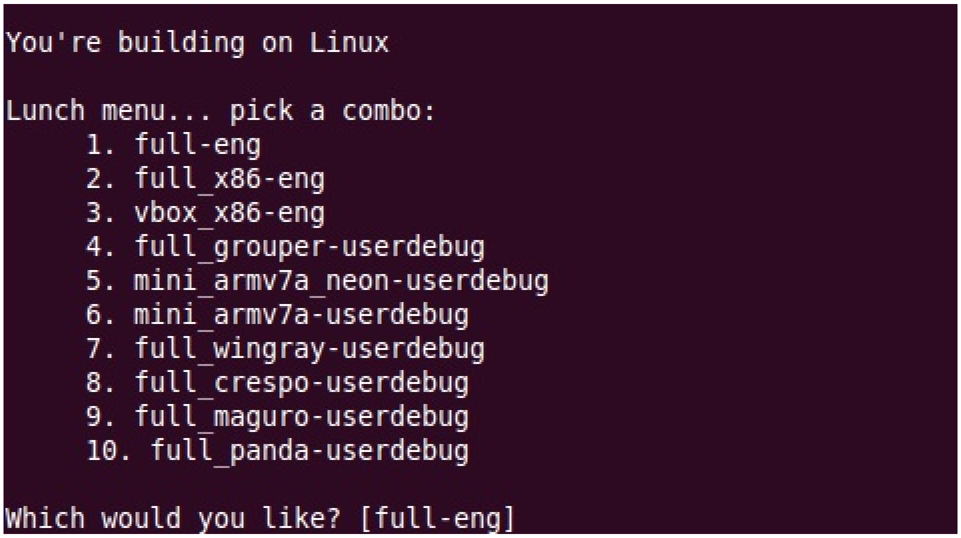

▲图2-5　使用“lunch”来显示所有产品

Step3. 执行编译命令

最直接的就是输入如下命令：

```
$ make
```

对于2.3以下的版本，整个编译过程在一台普通计算机上需要3小时以上的时间。而对于JellyBean以上的项目，很可能会花费5小时以上的时间（这取决于你的宿主机配置）。

如果希望充分利用CPU资源，也可以使用make选项“-jN”。N的值取决于开发机器的CPU数、每颗CPU的核心数以及每个核心的线程数。

例如，你可以使用以下命令来加快编译速度：

```
$ make –j4
```

有个小技巧可以为这次编译轻松地打上Build Number标签，而不需要特别更改脚本文件，即在make之前输入如下命令：

```
$ export BUILD_NUMBER=${USER}-'date +%Y%m%d-%H%M%S'
```

在定义BUILD_NUMBER变量值时要特别注意容易引起错误的符号，如“$”“&”“:”“/”“\”“<”“>”等。

这样我们就成功编译出Android原生态系统了——当然，上面的“make”指令只是选择默认的产品进行编译。假如你希望针对某个特定的产品来执行，还需要先通过上一小节中的“lunch”进行相应的选择。

接下来看看如何编译出SDK。这是很多开发者，特别是应用程序研发人员所关心的。因为很多时候通过SDK所带的模拟器来调试APK应用，比在真机上操作要来得高效且便捷；而且模拟器可以配置出各种不同的屏幕参数，用以验证应用程序的“适配”能力。

SDK是运行于Host机之上的，因而编译过程根据宿主操作系统的不同会有所区别。详细步骤如下：

Mac OS和Linux

（1）下载源码，和前面已经讲过的源码下载过程没有任何区别。

（2）执行envsetup.sh。

（3）选择SDK对应的产品。

```
$ lunch sdk-eng
```

提示：如果通过“lunch”没有出现“sdk”这个种类的产品也没有关系，可以直接输入上面的命令。

（4）最后，使用以下命令进行SDK编译：

```
$ make sdk
```

Windows

运行于Windows环境下的SDK编译需要基于上面Linux的编译结果（注意只能是Linux环境下生成的结果，而不支持MacOS）。

（1）执行Linux下SDK编译的所有步骤，生成Linux版的SDK。

（2）安装额外的支持包。

```
$ sudo apt-get install mingw32 tofrodos
```

（3）再次执行编译命令，即：

```
$ . ./build/envsetup.sh
$ lunch sdk-eng
$ make win_sdk
```

这样我们就完成Windows版本SDK的编译了。

当然上面编译SDK的过程也同样可以利用多核心CPU的优势。例如：

```
$ make -j4 sdk
```

面向Host和Target的编译结果都存放在源码工程out目录下，分为两个子目录。

- host：SDK生成的文件存放在这里。例如：
    - MacOS

      out/host/darwin-x86/sdk/android-sdk_eng.<build-id>_mac-x86.zip
    - Windows

      out/host/windows/sdk/android-sdk_eng.${USER}_windows/
- target：通过make命令生成的文件存放在这里。

另外，启动一个模拟器可以使用以下命令。

```
$ emulator [OPTIONS]
```

模拟器提供的启动选项非常丰富，读者可以参见本书工具篇中的详细描述。

2.3 定制产品的编译与烧录

上一小节我们学习了原生态Android系统的编译步骤，为大家进一步理解定制设备的编译流程打下了基础。Android系统发展到今天，已经在多个产品领域得到了广泛的应用。相信有一个问题是很多人都想了解的，那就是如何在原生态Android系统中添加自己的定制产品。

2.3.1 定制新产品

仔细观察整个Android源码项目可以发现，它的根目录下有一个device文件夹，其中又包含了诸如samsung、moto、google等厂商名录，如图2-6所示。

▲图2-6 device文件夹下的厂商目录

在Android编译系统中新增一款设备的过程如下。

Step 1. 和图2-6所列的各厂商一样，我们也最好先在device目录下添加一个以公司命名的文件夹。当然，Android系统本身并没有强制这样做（后面会看到vendor目录也是可以的），只不过规范的做法有利于项目的统一管理。

然后在这个公司名目录下为各产品分别建立对应的子文件夹。以samsung为例，其文件夹中包含的产品如图2-7所示。

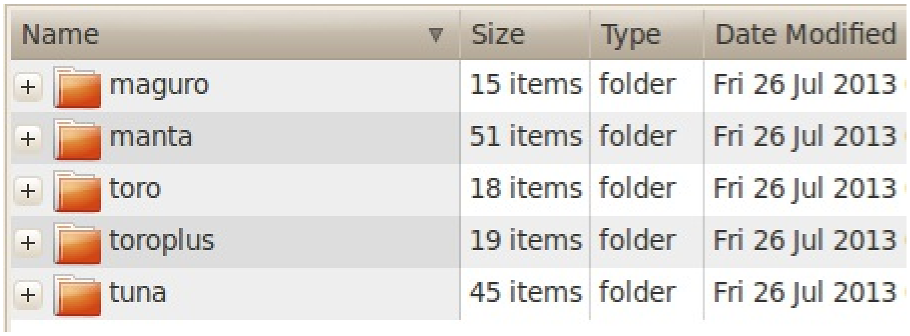

▲图2-7　一个厂商通常有多种产品

完成产品目录的添加后，和此项目相关的所有特定文件都应该优先放置到这里。一般的组织结构如图2-8所示。

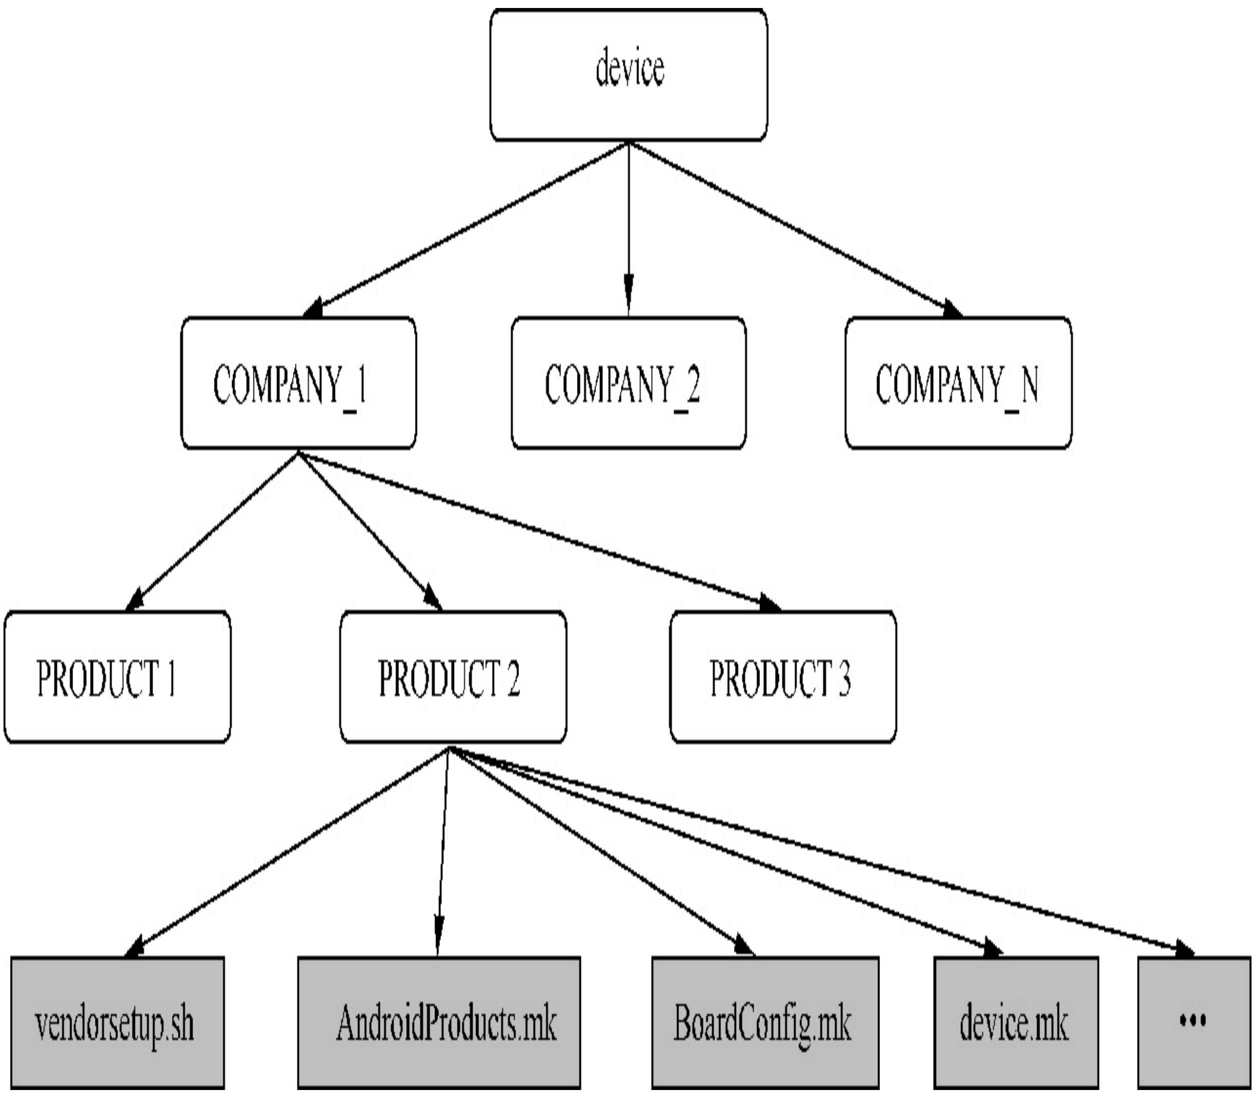

▲图2-8　device目录的组织架构

由图2-8最后一行可以看出，一款新产品的编译需要多个配置文件（sh、mk等）的支持。我们按照这些文件所处的层级进行一个系统的分类，如表2-5所示。

表2-5　定制新设备所需的配置文件分类

层　级	作　用
芯片架构层（Architecture）	产品所采用的硬件架构，如ARM、X86等
核心板层（Board）	硬件电路的核心板层配置
设备层（Device）	外围设备的配置，如有没有键盘
产品层（Product）	最终生成的系统需要包含的软件模块和配置，如是否有摄像头应用程序、默认的国家或地区语言等

也就是说，一款产品由底层往上的构建顺序是：芯片架构→核心板→设备→产品。这样讲可能有点抽象，给大家举个具体的例子。我们知道，当前嵌入式领域市场占有率最高的当属ARM系列芯片。但是首先，ARM公司本身并不生产具体的芯片，而只授权其他合作伙伴来生产和销售半导体芯片。ARM架构就是属于最底层的硬件体系，需要在编译时配置。其次，很多芯片设计商（如三星）在获得授权后，可以在ARM架构的基础上设计出具体的核心板，如S5PV210。接下来，三星会将其产品进一步销售给有需要的下一级厂商，如某手机生产商。此时就要考虑整个设备的硬件配置了，如这款手机是否要带有按键、触摸屏等。最后，

在确认了以上3个层次的硬件设计后，我们还可以指定产品的一些具体属性，如默认的国家或地区语言、是否带有某些应用程序等。

后续的步骤中我们将分别讲解与这几个层次相关的一些重要的脚本文件。

Step 2. vendorsetup.sh

虽然我们已经为新产品创建了目录，但Android系统并不知道它的存在——所以需要主动告知Android系统新增了一个“家庭成员”。以三星toro为例，为了让它能被正确添加到编译系统中，首先就要在其目录下新建一个vendorsetup.sh脚本。这个脚本通常只需要一个语句。具体范例如下：

```
add_lunch_combo  full_toro-userdebug
```

大家应该还记得前一小节编译原生态系统的第一步是执行envsetup.sh，函数add_lunch_combo就是在这个文件中定义的。此函数的作用是将其参数所描述的产品（如full_toro-userdebug）添加到系统相关变量中——后续lunch提供的选单即基于这些变量产生的。

那么，vendorsetup.sh在什么时候会被调用呢？

答案也是envsetup.sh。这个脚本的大部分内容是对各种函数进行定义与实现，末尾则会通过一个for循环来扫描工程中所有可用的vendorsetup.sh，并执行它们。具体源码如下：

```
# Execute the contents of any vendorsetup.sh files we can find.
for f in 'test -d device && find device -maxdepth 4 -name 'vendor
\
         'test -d vendor && find vendor -maxdepth 4 -name 'vendor
do
    echo "including $f"
    . $f
Done

unset f
```

可见，默认情况下编译系统会扫描如下路径来查找vendorsetup.sh：

```
/vendor/
/device/
```

注：vendor这个目录在4.3版本的Android工程中已经不存在了，建议开发者将产品目录统一放在device中。

打一个比方，上述步骤有点类似于超市的工作流程：工作人员（编译系统）首先要扫描仓库（vendor和device目录），统计出有哪些商品（由vendorsetup.sh负责记录），并通过一定的方式（add_lunch_combo@envsetup.sh）将物品上架，然后消费者才能在货架上挑选（lunch）自己想要的商品。

Step 3. 添加AndroidProducts.mk。消费者在货架上选择（lunch）了某样“商品”后，工作人员的后续操作（如结账、售后等）就完全基于这个特定商品来展开。编译系统会先在商品所在目录下寻找AndroidProducts.mk文件，这里记录着针对该款商品的一些具体属性。不过，通常我们只在这个文件中做一个“转向”。如：

```
/*device/samsung/toro/AndroidProducts.mk*/
PRODUCT_MAKEFILES := \
    $(LOCAL_DIR)/aosp_toro.mk \
    $(LOCAL_DIR)/full_toro.mk
```

因为AndroidProducts.mk对于每款产品都是通用的，不利于维护管理，所以可另外新增一个或者多个以该产品命名的makefile（如full_toro.mk和aosp_toro.mk），再让前者通过PRODUCT_MAKEFILES“指向”它们。

Step4. 实现上一步所提到的某产品专用的makefile文件（如full_toro.mk和aosp_toro.mk）。可以充分利用编译系统已有的全局变量或者函数来完成任何需要的功能。例如，指定编译结束后需要复制到设备系统中的各种文件、设置系统属性（系统属性最终会写入设备/system目录下的build.prop文件中）等。以full_toro.mk为例：

```
/*device/samsung/toro/full_toro.mk*/
#将apns等配置文件复制到设备的指定目录中
PRODUCT_COPY_FILES += \
    device/samsung/toro/bcmdhd.cal:system/etc/wifi/bcmdhd.cal \
    device/sample/etc/apns-conf_verizon.xml:system/etc/apns-conf.
…
# 继承下面两个mk文件
```

```
$(call inherit-product, $(SRC_TARGET_DIR)/product/aosp_base_telep
$(call inherit-product, device/samsung/toro/device_vzw.mk)
# 下面重载编译系统中已经定义的变量
PRODUCT_NAME :=full_toro  #产品名称
PRODUCT_DEVICE := toro #设备名称
PRODUCT_BRAND := Android  #品牌名称
…
```

这部分的变量基本上以“PRODUCT_”开头，我们在表2-6中对其中常用的一些变量做统一讲解。

表2-6　PRODUCT相关变量

变　量	描　述
PRODUCT_NAME	产品名称，最终会显示在系统设置中的“关于设备”选项卡中
PRODUCT_DEVICE	设备名称
PRODUCT_BRAND	产品所属品牌
PRODUCT_MANUFACTURER	产品生产商
PRODUCT_MODEL	产品型号
PRODUCT_PACKAGES	系统需要预装的一系列程序，如APKs
	所支持的国家语言。格式如下：

PRODUCT_LOCALES	[两字节语言码]-[两字节国家码] 如en_GB de_DE 各语言间以空格分隔
PRODUCT_POLICY	本产品遵循的“策略”，如： android.policy_phone android.policy_mid
PRODUCT_TAGS	一系列以空格分隔的产品标签描述
PRODUCT_PROPERTY_OVERRIDES	用于重载系统属性。 格式：key=value 示例： ro.product.firmware=v0.4rc1 dalvik.vm.dexopt-data-only=1 这些属性最终会被存储在系统设备的/system/build.prop文件中

Step 5. 添加BoardConfig.mk文件。这个文件用于填写目标架构、硬件设备属性、编译器的条件标志、分区布局、boot地址、ramdisk大小等一系列参数（参见下一小节对系统映像文件的讲解）。下面是一个范例（因为toro中的BoardConfig主要引用了tuna的BoardConfig实现，所以我们直接讲解后者的实现）：

```
#/*device/samsung/tuna/BoardConfig.mk*/
TARGET_CPU_ABI := armeabi-v7a ## eabi即Embedded application binary
TARGET_CPU_ABI2 := armeabi
…
TARGET_NO_BOOTLOADER := true ##不编译bootloader
…
```

```
BOARD_SYSTEMIMAGE_PARTITION_SIZE := 685768704#system.img分区大小
BOARD_USERDATAIMAGE_PARTITION_SIZE := 14539537408#userdata.img的分
BOARD_FLASH_BLOCK_SIZE := 4096 #flash块大小
…
BOARD_WLAN_DEVICE      := bcmdhd #wifi设备
```

可以看到，这个makefile文件中涉及的变量大部分以“TARGET_”和“BOARD_”开头，且数量众多。相信对于第一次编写BoardConfig.mk的开发者来说，这是一个不小的挑战。那么，有没有一些小技巧来加速学习呢？

答案是肯定的。

各大厂商在自己产品目录下存放的BoardConfig.mk样本就是我们学习的绝佳材料。通过比较可发现，这些文件大部分都是雷同的。所以我们完全可以先从中复制一份（最好选择架构、主芯片与自己项目相当的），然后根据产品的具体需求进行修改。

Step 6. 添加Android.mk。这是Android系统下编译某个模块的标准makefile。有些读者可能分不清楚这个文件与前面几个步骤中的makefile有何区别。我们举例说明，如果Step1-Step5中的文件用于决定一个产品的属性，那么Android.mk就是生产这个“产品”某个“零件”的“生产工序”。——要特别注意，只是某个“零件”而已。整个产品是需要由很多Android.mk生产出的“零件”组合而成的。

Step7. 完成前面6个步骤后，我们就成功地将一款新设备定制到编译系统中了。接下来的编译流程和原生态系统是完全一致的，这里不再赘述。

值得一提的是，/system/build.prop这个文件的生成过程也是由编译系统控制的。具体处理过程在/build/core/Makefile中，它主要由以下几个部分组成：

- /build/tools/buildinfo.sh

这个脚本用于向build.prop中输出各种<key> <value>组合，实现方式也很简单。下面是其中的两行节选：

```
echo "ro.build.id=$BUILD_ID"
```

echo "ro.build.display.id=$BUILD_DISPLAY_ID"

- TARGET_DEVICE_DIR目录下的system.prop
- ADDITIONAL_BUILD_PROPERTIES
- /build/tools/post_process_props.py

清理工作，将黑名单中的项目从最终的build.prop中移除。

开发人员在定制一款新设备时，可以根据实际情况将自己的配置信息添加到上述几个组成部分中，以保证设备的正常运行。

2.3.2 Linux内核编译

不同产品的硬件配置往往是有差异的。比如某款手机配备了蓝牙芯片，而另一款则没有；即便是都内置了蓝牙模块的两款手机，它们的生产商和型号也很可能不一样——这就不可避免地要涉及内核驱动的移植。前面我们分析的编译流程只针对Android系统本身，而Linux内核和Android的编译是独立的。因此对于设备开发商来说，还需要下载、修改和编译内核版本。

接下来以Android官方提供的例子来讲解如何下载合适的内核版本。

这个范例基于Google的Panda设备，具体步骤如下。

Step1. 首先通过以下命令来获取到git log：

```
$ git clone https://android.googlesource.com/device/ti/panda
$ cd panda
$ git log --max-count=1 kernel
```

这样就得到了panda kernel的提交值，在后续步骤中会用到。

Step2. Google针对Android系统提供了以下可用的内核版本：

```
$ git clone https://android.googlesource.com/kernel/common.git
$ git clone https://android.googlesource.com/kernel/exynos.git
$ git clone https://android.googlesource.com/kernel/goldfish.git
$ git clone https://android.googlesource.com/kernel/msm.git
$ git clone https://android.googlesource.com/kernel/omap.git
```

```
$ git clone https://android.googlesource.com/kernel/samsung.git
$ git clone https://android.googlesource.com/kernel/tegra.git
```

上述命令的每一行都代表了一个可用的内核版本。

那么，它们之间有何区别呢？

- exynos，适用于Samsung Exynos芯片组；
- goldfish，适用于模拟平台；
- msm，适用于ADP1，ADP2，Nexus One以及Qualcomm MSM芯片组；
- omap，适用于PandaBoard和Galaxy Nexus以及TI OMAP芯片组；
- samsung，适用于Nexus S以及Samsung Hummingbird芯片组；
- tegra，适用于Xoom以及NVIDIA Tegra芯片组；
- common，则是通用版本。

由此可见，与Panda设备相匹配的是omap.git这个版本的内核。

Step3. 除了Linux内核，我们还需要下载prebuilt。具体命令如下：

```
$ git clone https://android.googlesource.com/platform/prebuilt
$ export PATH=$(pwd)/prebuilt/linux-x86/toolchain/arm-eabi-4.4.3/
```

Step4. 完成以上步骤后，就可以进行Panda内核的编译了：

```
$ export ARCH=arm
$ export SUBARCH=arm
$ export CROSS_COMPILE=arm-eabi-
$ cd omap
$ git checkout <第一步获取到的值>
$ make panda_defconfig
$ make
```

整个内核的编译相对简单，读者可以自行尝试。

2.3.3 烧录/升级系统

将编译生成的可执行文件包通过各种方式写入硬件设备的过程称为烧录（flash）。烧录的方式有很多，各厂商可以根据实际的需求自行

选择。常见的有以下几种。

（1）SD卡工厂烧录方式

当前市面上的CPU主芯片通常会提供多种跳线方式，来支持嵌入式设备从不同的存储介质（如Flash、SD Card等）中加载引导程序并启动系统。这样的设计显然会给设备开发商带来更多的便利。研发人员只需要将烧录文件按一定规则先写入SD卡，然后将设备配置为SD卡启动。一旦设备成功启动后，处于烧写模式下的BootLoader就会将各文件按照要求写入产品存储设备（通常是FLASH芯片）的指定地址中。

由此可见Bootloader的主要作用有两个：其一是提供下载模式，将组成系统的各个Image写入到设备的永久存储介质中；其二才是在设备开机过程中完成引导系统正常启动的重任。

一个完整的Android烧录包至少需要由3部分内容（即Boot Loader，Linux Kernel和Android System）组成。我们可以利用某种方式对它们先进行打包处理，然后统一写入设备中。一般情况下，芯片厂商（如Samsung）会针对某款或某系列芯片提供专门的烧录工具给开发人员使用；否则各产品开发商需要根据实际情况自行研发合适的工具。

总的来说，SD卡的烧录手法以其操作简便、不需要PC支持等优点被广泛应用于工厂生产中。

（2）USB方式

这种方式需要在PC的配合下完成。设备首先与PC通过USB进行连接，然后运行于PC上的客户端程序将辅助Android设备来完成文件烧录。

（3）专用的烧写工具

比如使用J-Tag进行系统烧录。

（4）网络连接方式

这种方式比较少见，因为它要求设备本身能接入网络（局域网、互联网），这对于很多嵌入式设备来说过于苛刻。

（5）设备Bootloader+fastboot的模式

这也就是我们俗称的“线刷”。需要特别注意的是，能够使用这种升级模式的一个前提是设备中已经存在可用的Bootloader，因而它不能被运用于工厂烧录中（此时设备中还未有任何有效的系统程序）。

当然，各大厂商通常还会在这种模式上做一些“易用性的封装”（譬如提供带GUI界面的工具），从而在一定程度上降低用户的使用门槛。

迫使Android设备进入Bootloader模式的方法基本上大同小异，下面这两种是最常见的：

通过“fastboot reboot-bootloader”命令来重启设备并进入Bootloader模式；

在关机状态下，同时按住设备的“音量减”和电源键进入Bootloader模式。

（6）Recovery模式

和前一种方式类似，Recovery模式同样不适用于设备首次烧录的场景。“Recovery”的字面意思是“还原”，这也从侧面反映出它的初衷是帮助那些出现异常的系统进行快速修复。由于OTA这种得到大规模应用的升级方式同样需要借助于Recovery模式，使得后者逐步超出了原先的设计范畴，成为普通消费者执行设备升级操作的首选方式。我们将在后续小节中对此做更详细的讲解。

2.4 Android Multilib Build

早期的Android系统只支持32位CPU架构的编译，但随着越来越多的64位硬件平台的出现，这种编译系统的局限性就突显出来了。因而Android系统推出了一种新的编译方式，即Multilib build。可想而知，这种编译系统上的改进需要至少满足两个条件：

- 支持64-bit和32-bit

64位和32位平台在很长一段时间内都需要“和谐共处”，因而编译系统必须保证以下几个场景。

Case1：支持只编译64-bit系统。

Case2：支持只编译32-bit系统。

Case3：支持编译64和32bit系统，64位系统优先。

Case4：支持编译32和64位系统，32位系统优先。

- 在现有编译系统基础上不需要做太多改动

事实上Multilib Build提供了比较简便的方式来满足以上两个条件，我们将在下面内容中学习到它的具体做法。

（1）平台配置

BoardConfig.mk用于指定目标平台相关的很多属性，我们可以在这个脚本中同时指定Primary和Secondary的CPU Arch和ABI：

与Primary Arch相关的变量有TARGET_ARCH、TARGET_ARCH_VARIANT、TARGET_CPU_VARIANT等，具体范例如下：

```
TARGET_ARCH := arm64
TARGET_ARCH_VARIANT := armv8-a
TARGET_CPU_VARIANT := generic
TARGET_CPU_ABI := arm64-v8a
```

与Secondary Arch相关的变量有TARGET_2ND_ARCH、TARGET_2ND_ARCH_VARIANT、TARGET_2ND_CPU_VARIANT等，具体范例如下：

```
TARGET_2ND_ARCH := arm
TARGET_2ND_ARCH_VARIANT := armv7-a-neon
TARGET_2ND_CPU_VARIANT := cortex-a15
TARGET_2ND_CPU_ABI := armeabi-v7a
TARGET_2ND_CPU_ABI2 := armeabi
```

如果希望默认编译32-bit的可执行程序，可以设置：

```
TARGET_PREFER_32_BIT := true
```

通常lunch列表中会针对不同平台提供相应的选项，如图2-9所示。

```
Lunch menu... pick a combo:
     1. aosp_arm-eng
     2. aosp_arm64-eng
     3. aosp_mips-eng
     4. aosp_mips64-eng
     5. aosp_x86-eng
     6. aosp_x86_64-eng
```

▲图2-9　相应的选项

当开发者选择不同平台时，会直接影响到TARGET_2ND_ARCH等变量的赋值，从而有效控制编译流程。比如图2-10中左、右两侧分别对应我们使用lunch 1和lunch 2所产生的结果，大家可以对比下其中的差异。

```
TARGET_PRODUCT=aosp_arm
TARGET_BUILD_VARIANT=eng
TARGET_BUILD_TYPE=release
TARGET_BUILD_APPS=
TARGET_ARCH=arm
TARGET_ARCH_VARIANT=armv7-a
TARGET_CPU_VARIANT=generic
TARGET_2ND_ARCH=
TARGET_2ND_ARCH_VARIANT=
TARGET_2ND_CPU_VARIANT=
HOST_ARCH=x86_64
HOST_OS=linux
```

```
TARGET_PRODUCT=aosp_arm64
TARGET_BUILD_VARIANT=eng
TARGET_BUILD_TYPE=release
TARGET_BUILD_APPS=
TARGET_ARCH=arm64
TARGET_ARCH_VARIANT=armv8-a
TARGET_CPU_VARIANT=generic
TARGET_2ND_ARCH=arm
TARGET_2ND_ARCH_VARIANT=armv7-a-neon
TARGET_2ND_CPU_VARIANT=cortex-a15
HOST_ARCH=x86_64
HOST_OS=linux
```

▲图2-10　控制编译流程

另外，还可以设置TARGET_SUPPORTS_32_BIT_APPS和TARGET_SUPPORTS_64_BIT_APPS来指明需要为应用程序编译什么版本的本地库。此时需要特别注意：

- 如果这两个变量被同时设置，那么系统会编译64-bit的应用程序——除非你设置了TARGET_PREFER_32_BIT或者在Android.mk中对变量做了重载；
- 如果只有一个变量被设置了，那么就只编译与之对应的应用程序；
- 如果两个变量都没有被设置，那么除非你在Android.mk中做了变量重载，否则默认只编译32-bit应用程序。

那么在支持不同位数的编译时，所采用的Tool Chain是否有区别？答案是肯定的。

如果你希望使用通用的GCC工具链来同时处理两种Arch架构，那么可以使用TARGET_GCC_VERSION_EXP；反之你可以使用TARGET_TOOLCHAIN_ROOT和2ND_TARGET_TOOLCHAIN_ROOT来为64和32位编译分别指定不同的工具链。

（2）单模块配置

我们当然也可以针对单个模块来配置Multilib。

- 对于可执行程序，编译系统默认情况下只会编译出64-bit的版本。除非我们指定了TARGET_PREFER_32_BIT或者

LOCAL_32_BIT_ONLY。

- 对于某个模块依赖的库的编译方式，会和该模块有紧密关系。简单来讲32-bit的库或者可执行程序依赖的库，会被以32位来处理;对于64位的情况也同样如此。

需要特别注意的是，在make命令中直接指定的目标对象只会产生64位的编译。举一个例子来说，“lunch aosp_arm64-eng”➞“make libc”只会编译64-bit的libc。如果你想编译32位的版本，需要执行“make libc_32”。

描述单模块编译的核心脚本是Android.mk，在这个文件里我们可以通过指定LOCAL_MULTILIB来改变默认规则。各种取值和释义如下所示：

- “first”

  只考虑Primary Arch的情况

- “both”

  同时编译32和64位版本

- “32”

  只编译32位版本

- “64”

  只编译64位版本

- “”

这是默认值。编译系统会根据其他配置来决定需要怎么做，如LOCAL_MODULE_TARGET_ARCH，LOCAL_32_BIT_ONLY等。

如果你需要针对某些特定的架构来做些调整，那么以下几个变量可能会帮到你：

- LOCAL_MODULE_TARGET_ARCH

可以指定一个Arch列表，例如“arm x86 arm64”等。这个列表用于指定你的模块所支持的arch范围，换句话说，如果当前正在编译的arch不在列表中将导致本模块不被编译：

- LOCAL_MODULE_UNSUPPORTED_TARGET_ARCH

如其名所示，这个变量起到和上述变量相反的作用。

- LOCAL_MODULE_TARGET_ARCH_WARN
- LOCAL_MODULE_UNSUPPORTED_TARGET_ARCH_WARN

这两个变量的末尾多了个“WARN”，意思就是如果当前模块在编译时被忽略，那么会有warning打印出来。

各种编译标志也可以打上与Arch相应的标签，如以下几个例子：

- LOCAL_SRC_FILES_arm, LOCAL_SRC_FILES_x86
- LOCAL_CFLAGS_arm, LOCAL_CFLAGS_arm64
- LOCAL_LDFLAGS_arm, LOCAL_LDFLAGS_arm64

我们再来看一下安装路径的设置。对于库文件来说，可以使用LOCAL_MODULE_RELATIVE_PATH来指定一个不同于默认路径的值，这样32位和64位的库都会被放置到这里。对于可执行文件来说，可以分别使用以下两类变量来指定文件名和安装路径：

- LOCAL_MODULE_STEM_32, LOCAL_MODULE_STEM_64

分别指定32位和64位下的可执行文件名称。

- LOCAL_MODULE_PATH_32, LOCAL_MODULE_PATH_64

分别指定32位和64位下的可执行文件安装路径。

（3）Zygote

支持Multilib Build还需要考虑一个重要的应用场合，即Zygote。可想而知，Multilib编译会产生两个版本的Zygote来支持不同位数的应用程序，即Zygote64和Zygote32。早期的Android系统中，Zygote的启

动脚本被直接书写在init.rc中。但从Lollipop开始，这种情况一去不复返了。我们来看一下其中的变化：

```
/*system/core/rootdir/init.rc*/
import /init.${ro.hardware}.rc
import /init.${ro.zygote}.rc
```

根据系统属性ro.zygote的不同，init进程会调用不同的zygote描述脚本，从而启动不同版本的“孵化器”。以ro.zygote为“zygote64_32”为例，具体脚本如下：

```
/*system/core/rootdir/init.zygote64_32.rc*/
service zygote /system/bin/<strong>app_process64</strong> -Xzygot
-server --socket-name=zygote
    class main
    socket zygote stream 660 root system
    onrestart write /sys/android_power/request_state wake
    onrestart write /sys/power/state on
    onrestart restart media
    onrestart restart netd

service zygote_secondary /system/bin/<strong>app_process32</stron
socket-name=zygote_secondary
    class main
    socket zygote_secondary stream 660 root system
    onrestart restart zygote
```

这个脚本描述的是Primary Arch为64，Secondary Arch为32位时的情况。因为zygote的承载进程是app_process，所以我们可以看到系统同时启动了两个Service，即app_process64和app_process32。关于zygote启动过程中的更多细节，读者可以参考本书的系统启动章节，我们这里先不进行深入分析。

因为系统需要有两个不同版本的zygote同时存在，根据前面内容的学习我们可以断定，zygote的Android.mk中一定做了同时编译32位和64位程序的配置：

```
/*frameworks/base/cmds/app_process/Android.mk*/
LOCAL_SHARED_LIBRARIES := \
     libcutils \
     libutils \
     liblog \
     libbinder \
```

```
    libandroid_runtime

LOCAL_MODULE:= app_process
LOCAL_MULTILIB := <strong>both</strong>
LOCAL_MODULE_STEM_32 := app_process32
LOCAL_MODULE_STEM_64 := app_process64
include $(BUILD_EXECUTABLE)
```

上面这个脚本可以作为需要支持Multilib build的模块的一个范例。其中LOCAL_MULTILIB告诉系统，需要为zygote生成两种类型的应用程序；而LOCAL_MODULE_STEM_32和LOCAL_MODULE_STEM_64分别用于指定两种情况下的应用程序名称。

2.5　Android系统映像文件

通过前面几个小节的学习，我们已经按照产品需求编译出自定制的Android版本了。编译成功后，会在out/target/product/[YOUR_PRODUCT_NAME]/目录下生成最终要烧录到设备中的映像文件，包括system.img，userdata.img，recovery.img，ramdisk.img等。初次看到这些文件的读者一定想知道为什么会生成这么多的映像、它们各自都将完成什么功能。

这是本小节所要回答的问题。

Android中常见image文件包的解释如表2-7所示。

表2-7　Android系统常见image释义

Image	Description
boot.img	包含内核启动参数、内核等多个元素（详见后面小节的描述）
ramdisk.img	一个小型的文件系统，是Android系统启动的关键
system.img	Android系统的运行程序包（framework就在这里），将被挂载到设备中的/system节点下
userdata.img	各程序的数据存储所在，将被挂载到/data目录下
recovery.img	设备进入“恢复模式”时所需要的映像包
misc.img	即“miscellaneous”，包含各种杂项资源

cache.img	缓冲区，将被挂载到/cache节点中

它们的关系可以用图2-11来表示。

接下来对boot、ramdisk、system三个重要的系统image进行深入解析。

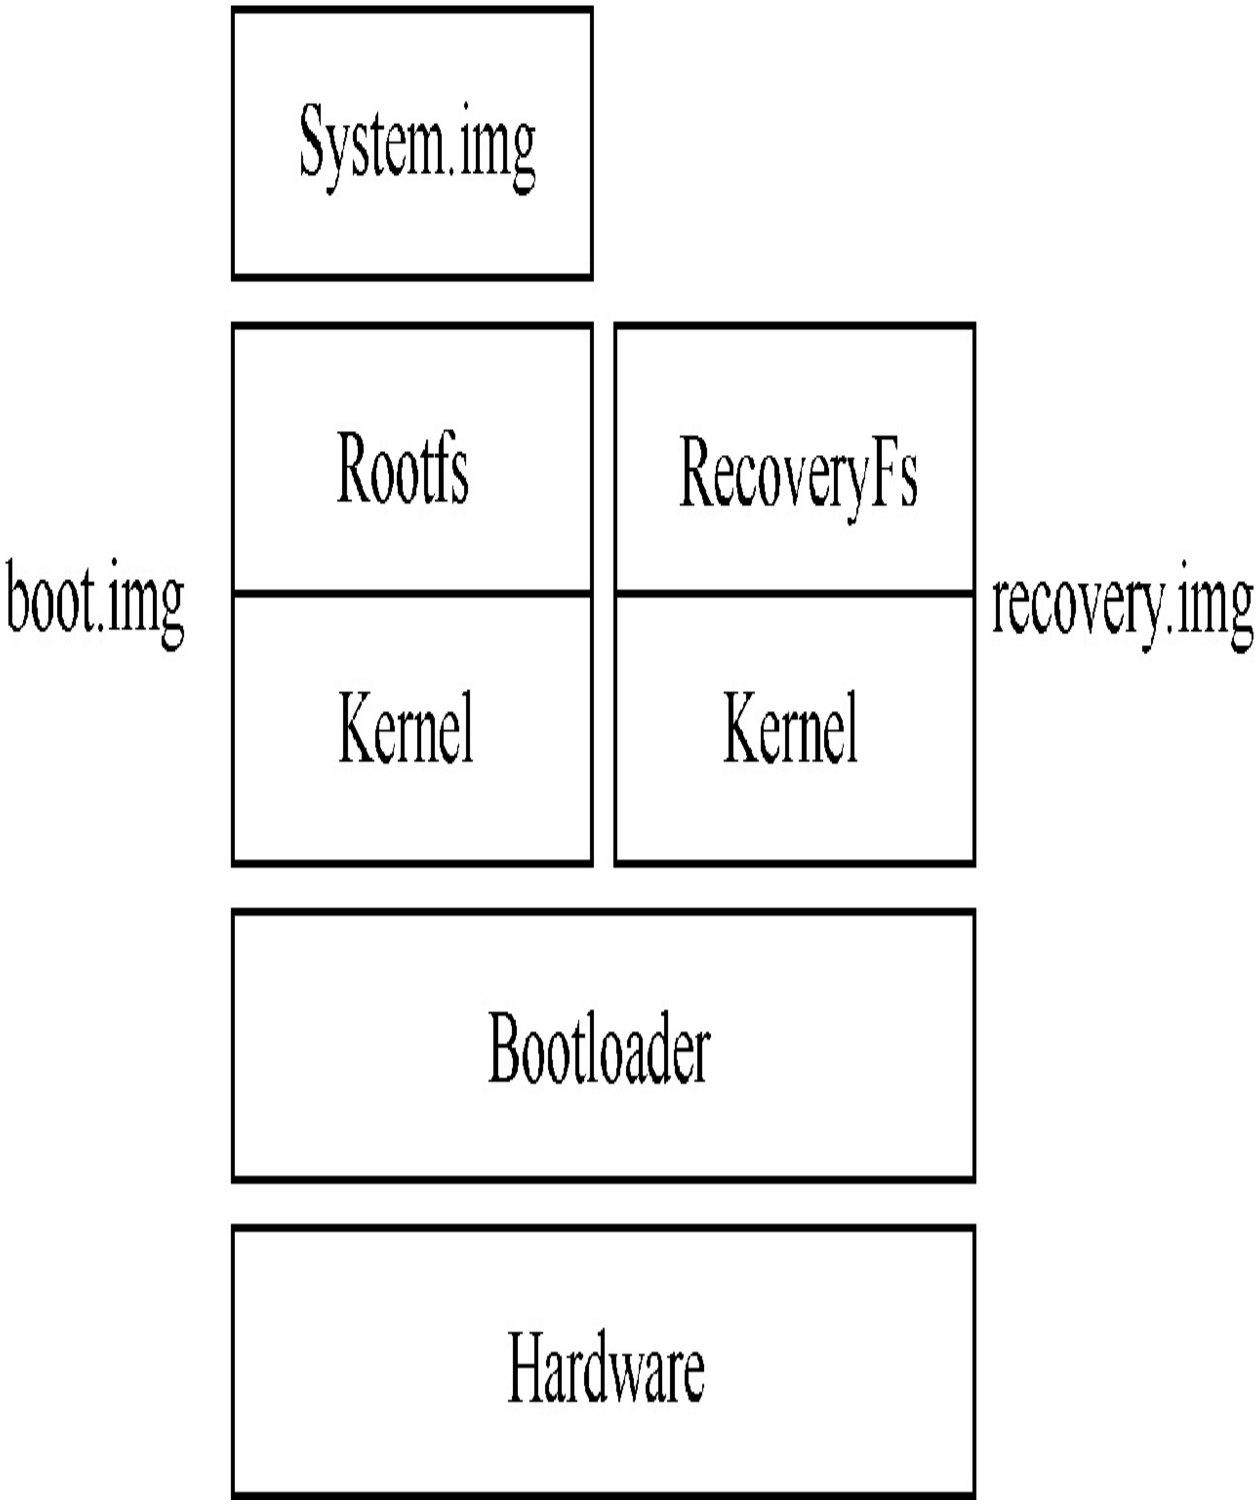

▲图2-11　关系图

2.5.1　boot.img

理解boot.img的最好方法就是学习它的制作工具—— mkbootimg，源码路径在system/core/ mkbootimg中。这个工具的语法规则如下：

```
mkbootimg  --kernel <filename> --ramdisk <filename>
[ --second <2ndbootloader-filename>]  [ --cmdline <kernel-command
 [ --board <boardname> ]  [ --base <address> ]
 [ --pagesize <pagesize> ]  -o|--output <filename>
```

--kernel：指定内核程序包（如zImage）的存放路径；

--ramdisk：指定ramdisk.img（下一小节有详细分析）的存放路径；

--second：可选，指第二阶段文件；

--cmdline：可选，内核启动参数；

--board：可选，板名称；

--base：可选，内核启动基地址；

--pagesize：可选，页大小；

--output：输出名称。

那么，编译系统是在什么地方调用mkbootimg的呢？

其一就是droidcore的依赖中，INSTALLED_BOOTIMAGE_TARGET，如图2-12所示。

```
droidcore: files \
	systemimage \
	$(INSTALLED_BOOTIMAGE_TARGET) \
	$(INSTALLED_RECOVERYIMAGE_TARGET) \
	$(INSTALLED_USERDATAIMAGE_TARGET) \
```

▲图2-12　droidcore的依赖

其二就是生成INSTALLED_BOOTIMAGE_TARGET的地方（build/core/Makefile），如图2-13所示。

```
$(INSTALLED_BOOTIMAGE_TARGET): $(MKBOOTIMG) $(INTERNAL_BOOTIMAGE_FILES)
  $(call pretty,"Target boot image: $@")
  $(hide) $(MKBOOTIMG) $(INTERNAL_BOOTIMAGE_ARGS) $(BOARD_MKBOOTIMG_ARGS) --output $@
  $(hide) $(call assert-max-image-size,$@,$(BOARD_BOOTIMAGE_PARTITION_SIZE),raw)
endif # TARGET_BOOTIMAGE_USE_EXT2
```

▲图2-13　生成INSTALLED_BOOTIMAGE_TARGET的地方

可见mkbootimg程序的各参数是由INTERNAL_BOOTIMAGE_ARGS和BOARD_MKBOOTIMG_ARGS来指定的，而这两者又分别取决于其他makefile中的定义。如BoardConfig.mk中定义的BOARD_KERNEL_CMDLINE在默认情况下会作为--cmdline参数传给mkbootimg；BOARD_KERNEL_BASE则作为--base参数传给mkbootimg。

按照Bootimg.h中的描述，boot.img的文件结构如图2-14所示。

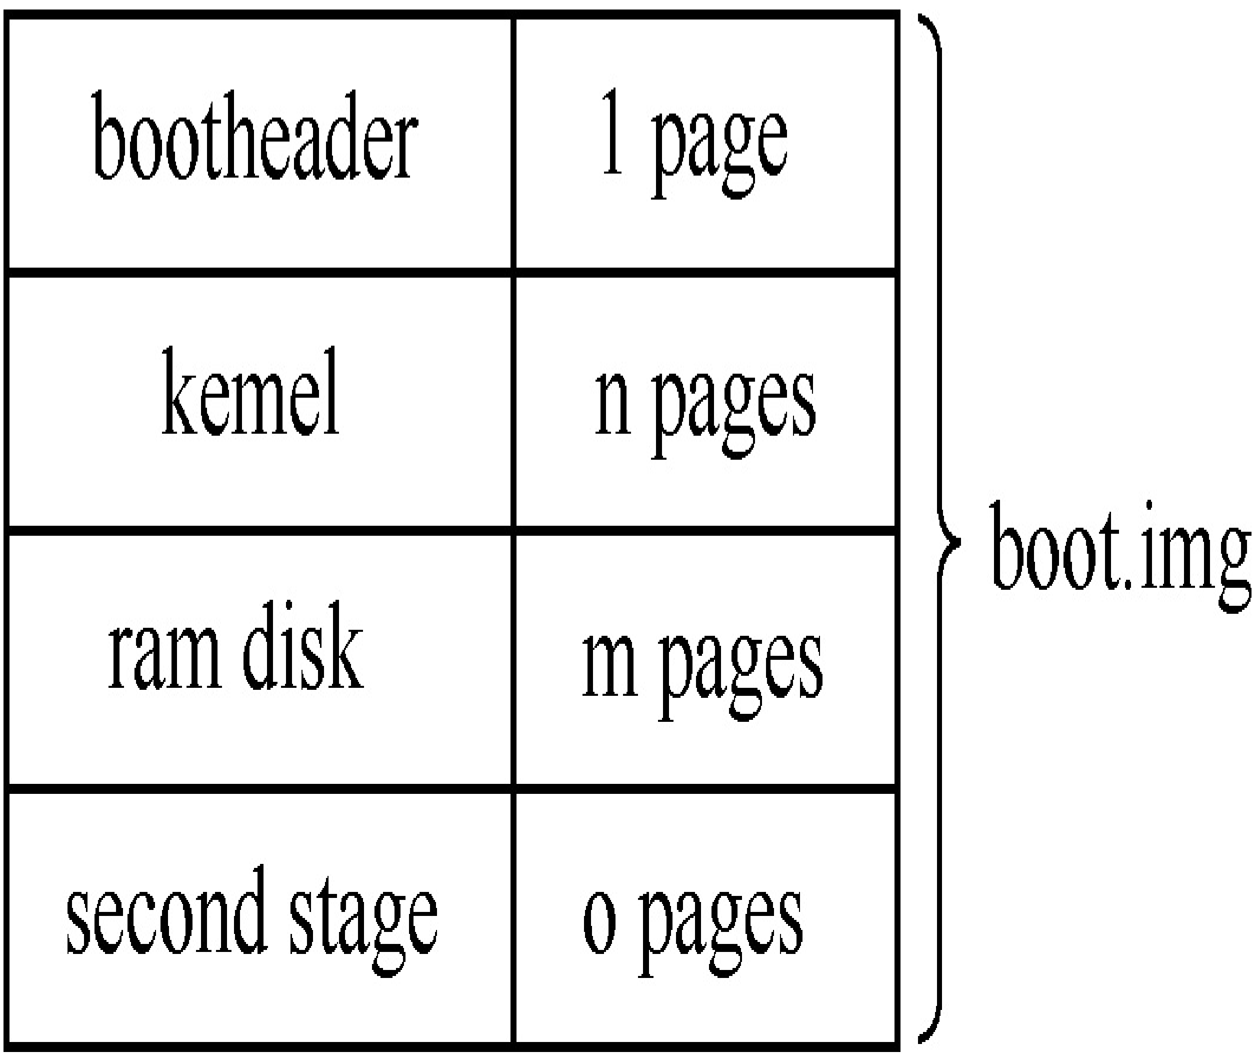

▲图2-14　boot.img的文件结构

各组成部分如下：

1．boot header

存储内核启动“头部”—— 内核启动参数等信息，占据一个page空间，即4KB大小。Header中包含的具体内容可以通过分析Mkbootimg.c中的main函数来获知，它实际上对应boot_img_hdr这个结构体：

```
/*system/core/mkbootimg/Bootimg.h*/
struct boot_img_hdr
{
    unsigned char magic[BOOT_MAGIC_SIZE];
    unsigned kernel_size;  /* size in bytes */
    unsigned kernel_addr;  /* physical load addr */
    unsigned ramdisk_size; /* size in bytes */
    unsigned ramdisk_addr; /* physical load addr */
    unsigned second_size;  /* size in bytes */
    unsigned second_addr;  /* physical load addr */
    unsigned tags_addr;    /* physical addr for kernel tags */
    unsigned page_size;    /* flash page size we assume */
    unsigned unused[2];    /* future expansion: should be 0 */
    unsigned char name[BOOT_NAME_SIZE]; /* asciiz product name */
    unsigned char cmdline[BOOT_ARGS_SIZE];
    unsigned id[8]; /* timestamp / checksum / sha1 / etc */
};
```

这样讲有点抽象，下面举个实际的boot.img例子，我们可以用UltraEditor或者WinHex把它打开，如图2-15所示。

可以看到，文件最起始的8个字节是“ANDROID!”，也称为BOOT_MAGIC；后续的内容则包括kernel_size，kernel_addr等，与上述的boot_img_hdr结构体完全吻合。

```
            0  1  2  3  4  5  6  7  8  9  a  b  c  d  e  f
00000000h: 41 4E 44 52 4F 49 44 21 DC 94 90 00 00 80 00 40 ; ANDROID!軒?.€.@
00000010h: D4 DE 10 00 00 00 00 41 00 00 00 00 00 00 F0 40 ; 赞.....A......睿
00000020h: 00 01 00 40 00 08 00 00 00 00 00 00 00 00 00 00 ; ...@............
00000030h: 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 ; ................
00000040h: 63 6F 6E 73 6F 6C 65 3D 74 74 79 53 30 2C 31 31 ; console=ttyS0,11
00000050h: 35 32 30 30 20 72 77 20 69 6E 69 74 3D 2F 69 6E ; 5200 rw init=/in
00000060h: 69 74 20 6C 6F 67 6C 65 76 65 6C 3D 35 00 00 00 ; it loglevel=5...
00000070h: 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 ; ................
00000080h: 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 00 ; ................
```

▲图2-15　boot header实例

2．kernel

内核程序是整个Android系统的基础，也被“装入”boot.img中——我们可以通过--kernel选项来指定内核映射文件的存储路径。其所占据的大小为：

```
n pages=(kernel_size + page_size - 1) / page_size
```

由此可以看出，boot.img中的各元素必须是页对齐的。

3．ramdisk

不仅是kernel，boot.img中也包含了ramdisk.img。其所占据大小为：

```
m pages=(ramdisk_size + page_size - 1) / page_size
```

可见也是页对齐的。

其他关于ramdisk的详细描述请参照下一小节，这里先不做解释。

4．second stage

这一项是可选的。其占据大小为：

```
o pages= (second_size + page_size - 1) / page_size
```

这个元素通常用于扩展功能，默认情况下可以忽略。

2.5.2　ramdisk.img

无论什么类型的文件，从计算机存储的角度来说都只不过是一堆“0”“1”数字的集合—— 它们只有在特定处理规则的解释下才能表现出意义。如txt文本用Ultra Editor打开就可以显示出里面的文字；jpg图像文件在Photoshop工具的辅助下可以让用户看到其所包含的内容。而文本与jpeg图像文件本质上并没有区别，只不过存储与读取这

一文件的“规则”发生了变化—— 正是这些“五花八门”的“规则”才创造出成千上万的文件类型。

另外，文件后缀名也并不是必需的，除非操作系统用它来鉴别文件的类型。而更多情况下，后缀名的存在只是为了让用户有个直观的认识。如我们会认为“*.txt”是文本文档、“*.jpg”是图片等。

Android的系统文件以“.img”为后缀名，这种类型的文件最初用来表示某个disk的完整复制。在从原理的层面讲解这些系统映像之前，可以通过一种方式来让读者对这些文件有个初步的感性认识（下面的操作以ramdisk.img为例，其他映像文件也是类似的）。

首先对ramdisk.img执行file命令，得到如下结果：

```
$file ramdisk.img
ramdisk.img: gzip compressed data, from Unix
```

这说明它是一个gZip的压缩文件。我们将其改名为ramdisk.img.gz，再进行解压。具体命令如下：

```
$gzip –d ramdisk.img.gz
```

这时会得到另一个名为ramdisk.img的文件，不过文件类型变了：

```
$file ramdisk.img
ramdisk.img: ASCII cpio archive (SVR4 with no CRC)
```

由此可知，这时的ramdisk.img是CPIO文件了。

再来执行以下操作：

```
$cpio -i -F ramdisk.img
3544 blocks
```

这样就解压出了各种文件和文件夹，范例如图2-16所示。

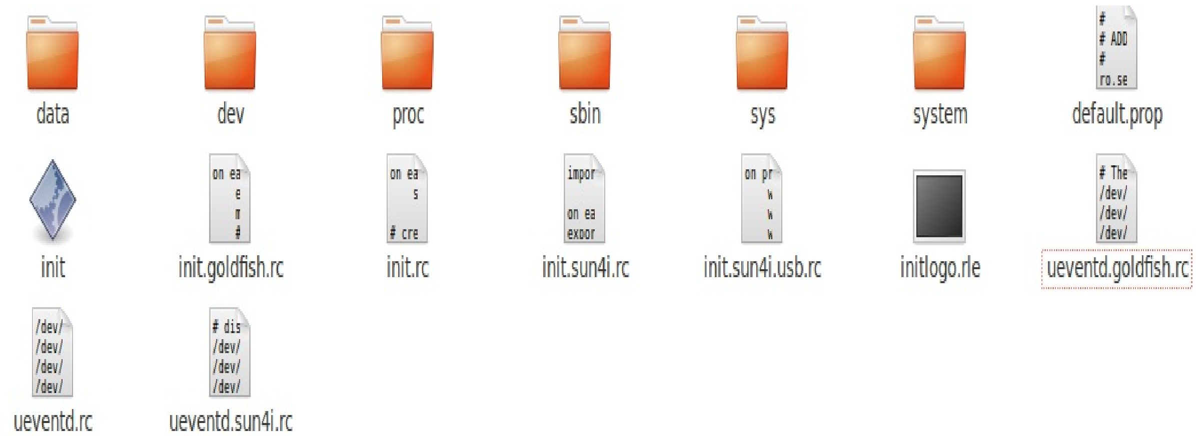

▲图2-16　范例

可以清楚地看到，常用的system目录、data目录以及init程序（系统启动过程中运行的第一个程序）等文件都包含在ramdisk.img中。

这样我们可以得出一个大致的结论，ramdisk.img中存放的是root根目录的镜像（编译后可以在out/target/product/[YOUR_PRODUCT_NAME]/root目录下找到）。它将在Android系统的启动过程中发挥重要作用。

2.5.3　system.img

要将system.img像ramdisk.img一样解压出来会相对麻烦一些。不过方法比较多，除了以下提到的方式，读者还可以尝试使用unyaffs（参考http://code.google.com/p/unyaffs/或者http://code.google.com/p/yaffs2utils/）来实现。

这里我们采取mount的方法，这是目前最省时省力的解决方式。

步骤如下：

- simg2img

编译成功后，这个工具的可执行文件在out/host/linux-x86/bin中。

源码目录 system/extras/ext4_utils。

将此工具复制到与system.img同一目录下。

执行如下命令可以查询simg2img的用法：

```
$ ./simg2img --h
Usage: simg2img <sparse_image_file><raw_image_file>
```

对system.img执行：

```
$ ./simg2img system.img system.img.step1
```

- mount

将上一步得到的文件通过以下操作挂载到system_extracted中：

```
$ mkdir system_extracted
$ sudo mount -o loop system.img.step1 system_extracted
```

最终我们得到如图2-17所示的结果。

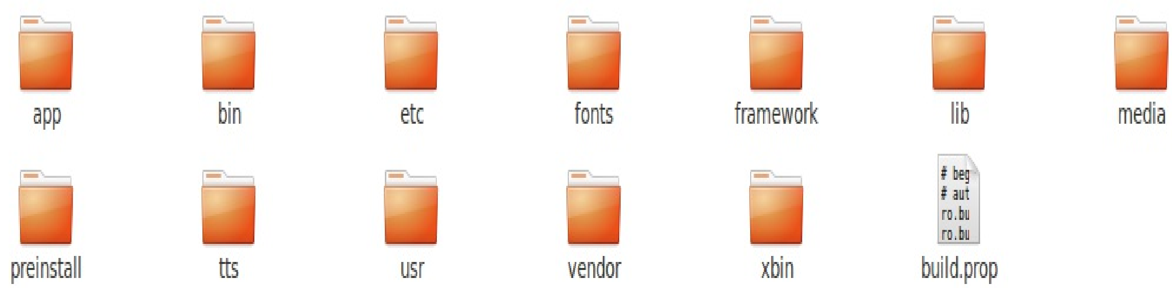

▲图2-17　结果图

这说明该image文件包含了设备/system节点中的相关内容。

2.5.4　Verified Boot

Android领域的开放性催生了很多第三方ROM的繁荣（例如市面上“五花八门”的Recovery、定制的Boot Image、System Image等），同时也给系统本身的安全性带来了挑战。

从4.4版本开始，Android结合Kernel的dm-verity驱动能力实现了一个名为“Verified Boot”的安全特性，以期更好地保护系统本身免

受恶意程序的侵害。我们在本小节将向大家讲解这一特性的基本原理，以便读者们在无法成功利用fastboot写入image时可以清楚地知道隐藏在背后的真正原因。

我们先来熟悉表2-8所示的术语。

当设备开机以后，根据Boot State和Device State的状态值不同，有如图2-18所示几种可能性。

表2-8　Verified Boot相关术语

术　语	释　义
dm-verity	Linux kernel的一个驱动，用于在运行时态验证文件系统分区的完整性（判断依据是Hash Tree和Signed metadata）
Boot State	保护等级，分为GREEN、YELLOW、ORANGE和RED四种
Device State	表明设备接受软件刷写的程度，通常有LOCKED和UNLOCKED两种状态
Keystore	公钥合集
OEM key	Bootloader用于验证boot image的key

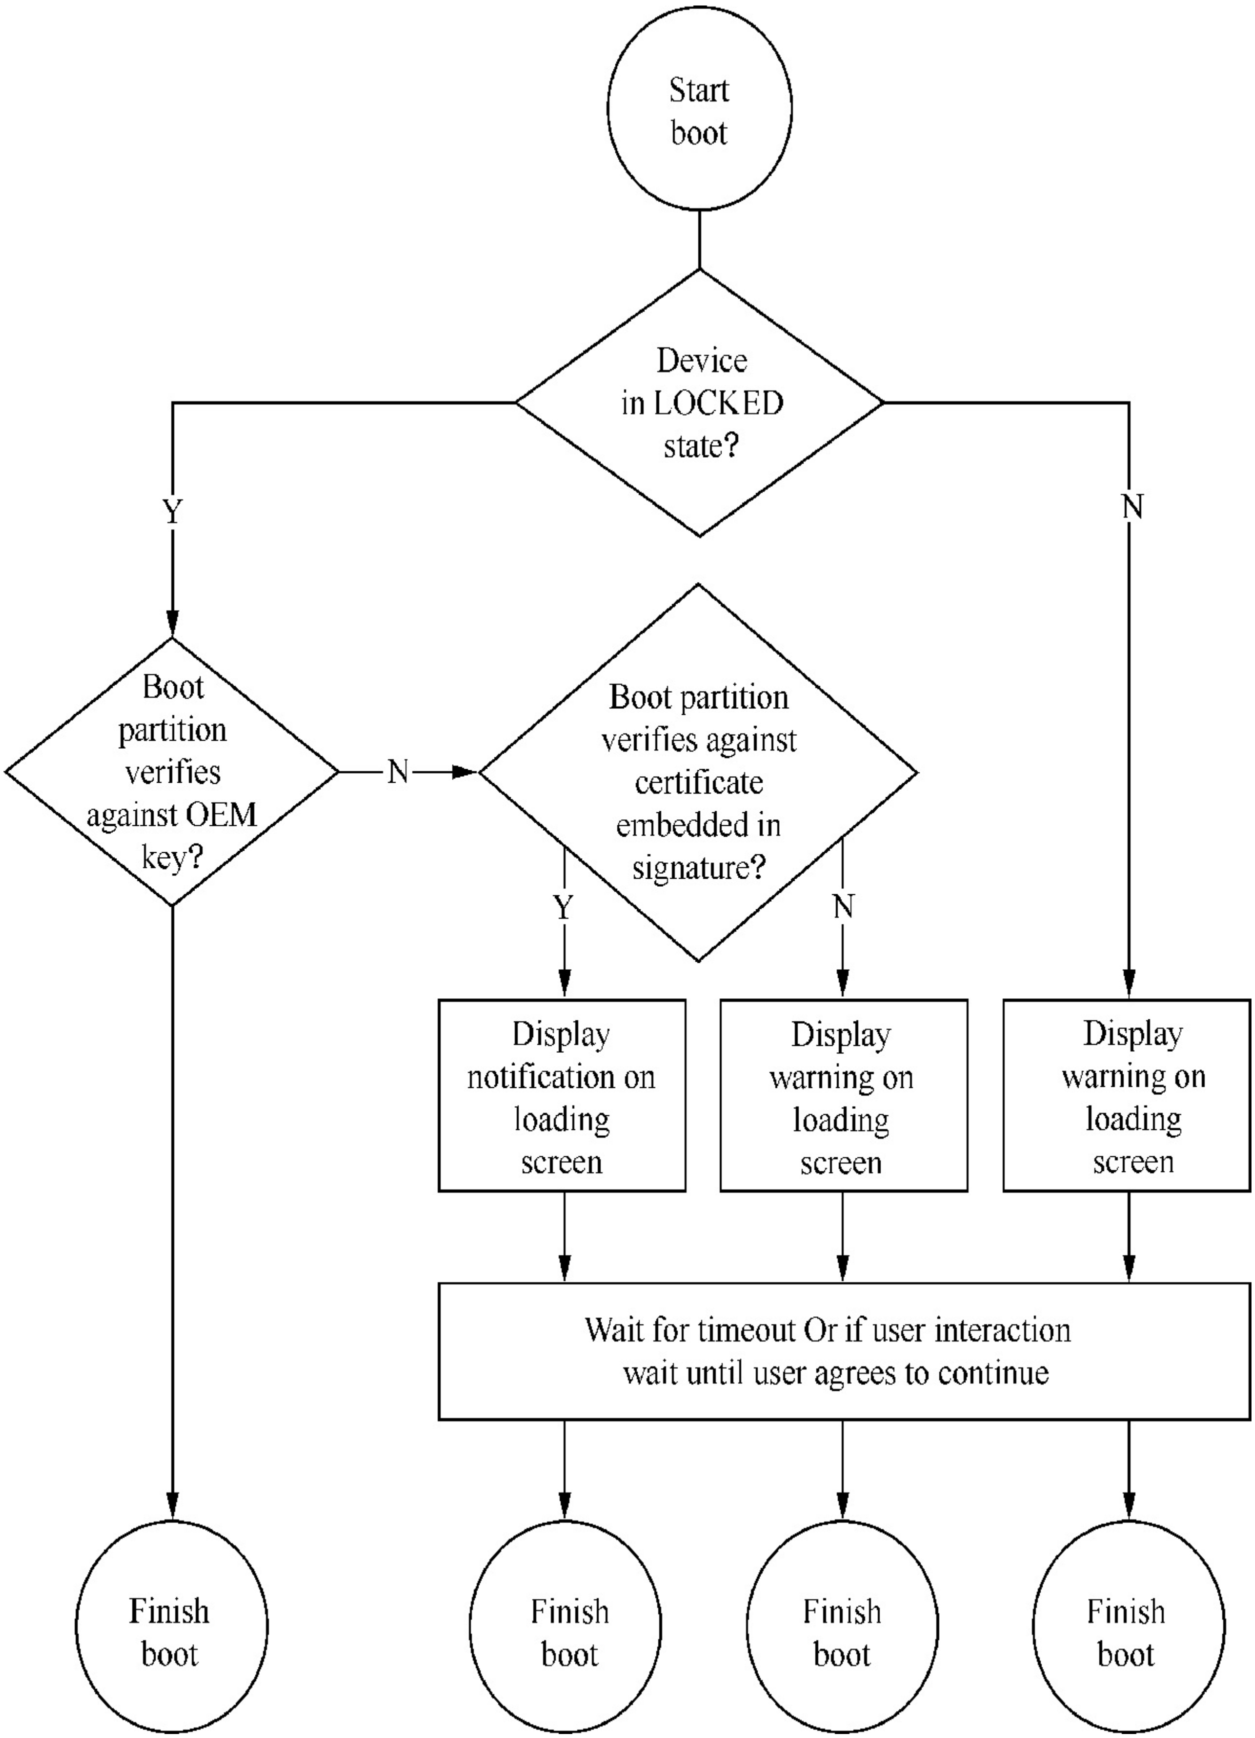

Start boot
Device in LOCKED state?
Y
N
Boot partition verifies against OEM key?
N
Boot partition verifies against certificate embedded in signature?
Y
N
Display notification on loading screen
Display warning on loading screen
Display warning on loading screen
Wait for timeout Or if user interaction wait until user agrees to continue
Finish boot
Finish boot
Finish boot
Finish boot

▲图2-18　Verified Boot总体流程
（引用自Android官方文档）

最下方的4个圆圈颜色分别为：GREEN、YELLOW、RED和ORANGE。例如当前设备的Device State是LOCKED，那么就首先需要经历OEM KEY Verification——如果通过的话Boot State是GREEN，表示系统是安全的；否则需要进入下一轮的Signature Verification，其结果决定了Boot State是YELLOW或者是RED（比较危险）。当然，如果当前设备本身就是UNLOCKED的，那就不用经过任何检验——不过它和YELLOW、RED一样的地方是，都会在屏幕上显式地告诫用户潜在的各种风险。部分Android设备还会要求用户主动做出选择后才能正常启动，如图2-19所示典型示例。

如果设备的Device State发生切换的话（fastboot就提供了类似的命令，只不过大部分设备都需要解锁码才能完成），那么系统中的data分区将会被擦除，以保证用户数据的安全。

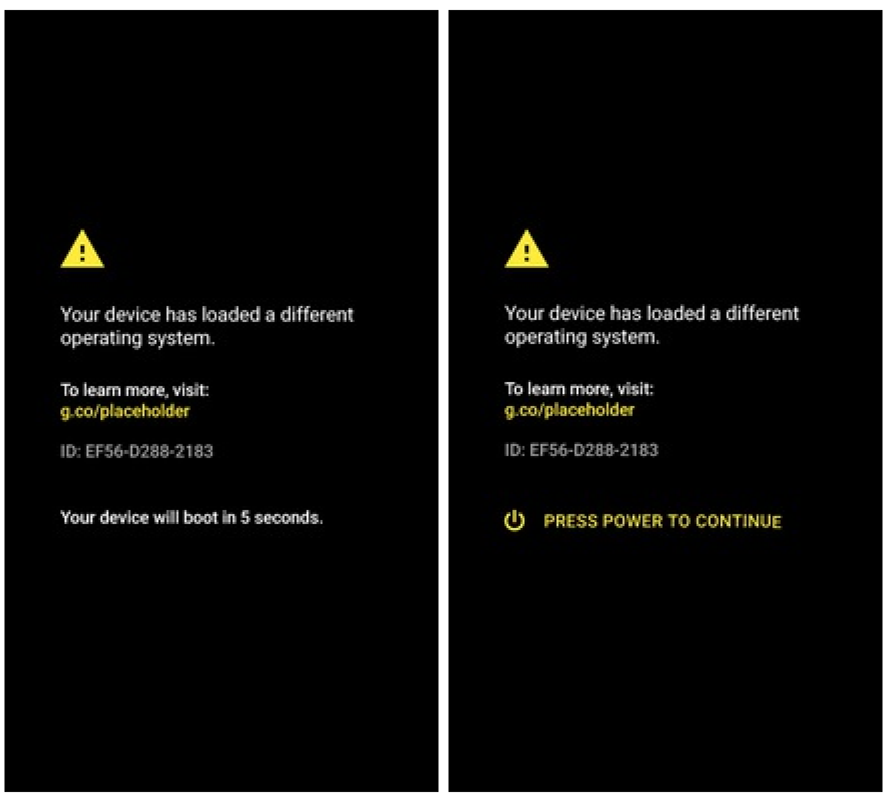

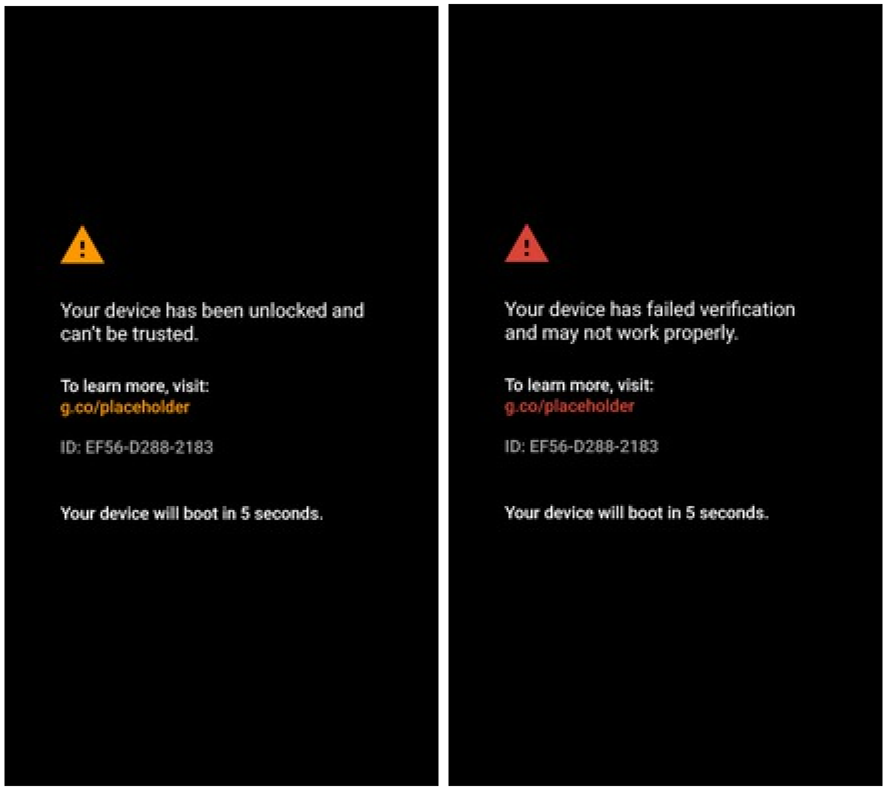

▲图2-19　典型示例

我们知道，Android系统在启动过程中要经过Bootloader->Kernel->Android三个阶段，因而在Verified Boot的设计中，它对分区的看护也是环环相扣的。具体来说，Bootloader承担boot和recovery分区的完整性校验职责；而Boot Partition则需要保证后续的分区，如system的安全性。另外，Recovery的工作和Boot是基本类似的。

不过，由于分区文件大小有差异，具体的检验手段也是不同的。结合前面小节对boot.img的描述，其在增加了verified boot后的文件结构变化如图2-20所示。

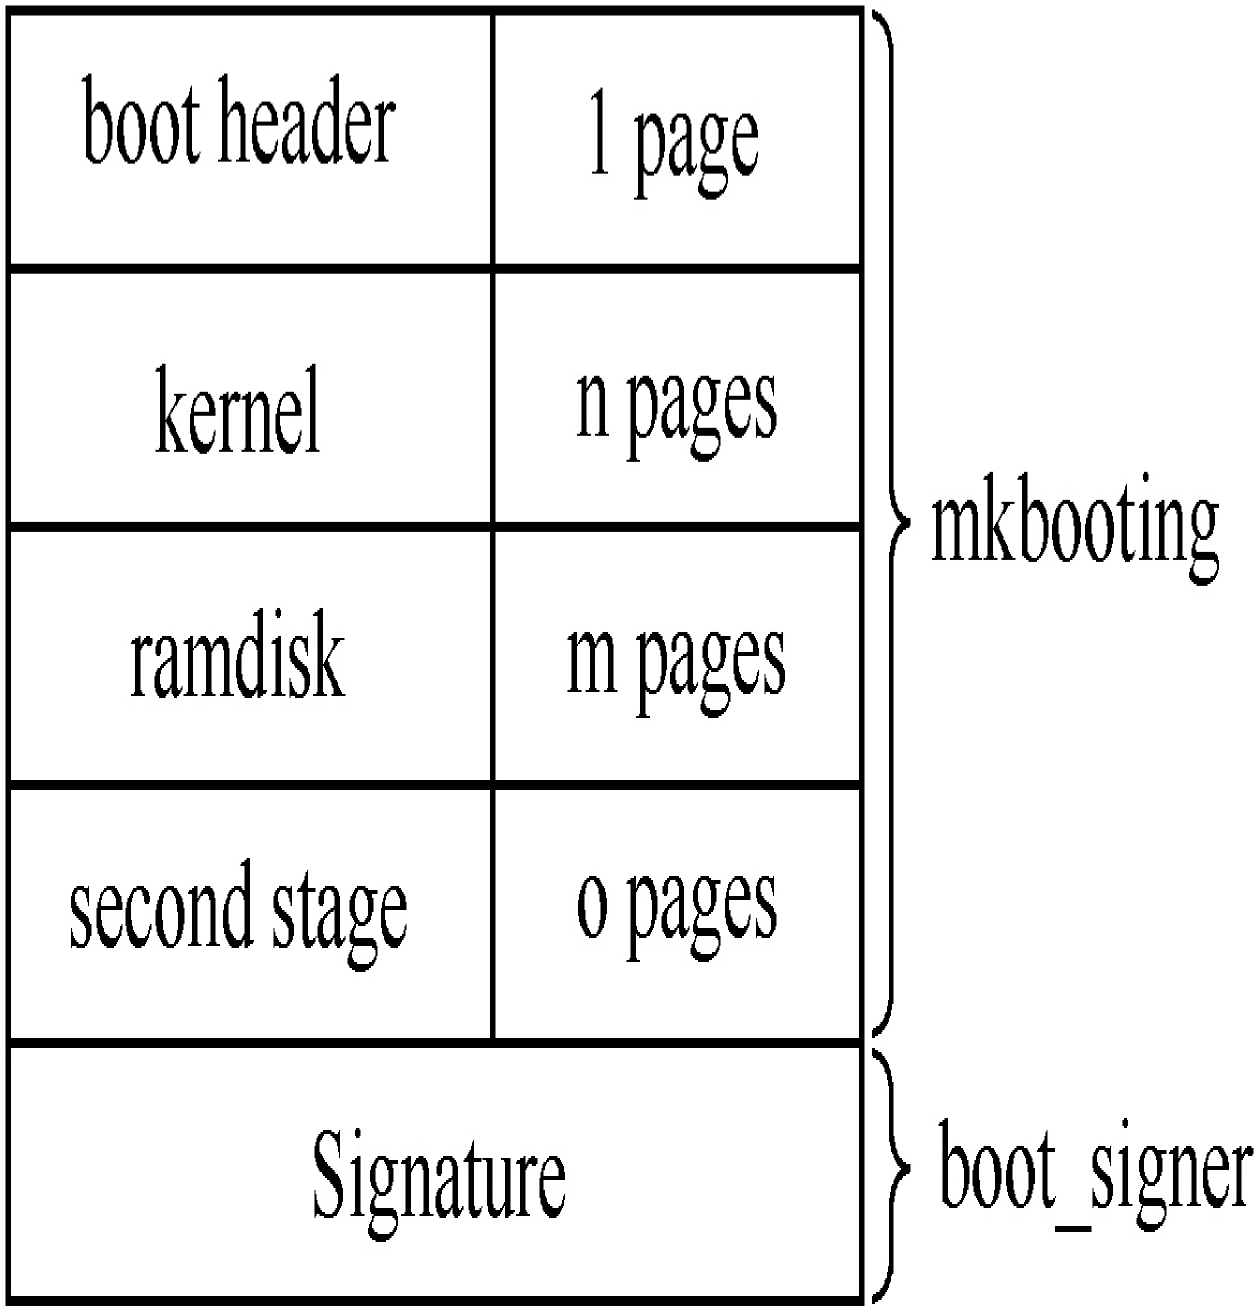

▲图2-20　文件结构变化

除了mkbootimg来生成原始的boot.img外，编译系统还会调用另一个新工具，即boot_signer（对应源码目录system/extras/verity）来在boot.img的尾部附加一个signature段。这个签名是针对boot.img的Hash结果展开的，默认使用的key在/build/target/product/security目录下。

而对于某些大块分区（如System Image），则需要通过dm-verity来验证它们的完整性。关于dm-verity还有非常多的技术细节，限于篇幅我们不做过多讨论，但强烈建议读者自行查阅相关资料做进一步深入学习。

2.6 ODEX流程

ODEX是Android旧系统的一个优化机制。对于很多开发人员来说，ODEX可以说是既熟悉又陌生。熟悉的原因在于目前很多手机系统，或者APK中的文件都从以前的格式变成了如图2-21和图2-22所示的样子。

而陌生的原因在于有关ODEX的资料并不是很多，不少开发人员对于ODEX是什么，能做什么以及它的应用流程并不清楚——这也是我们本小节所要向大家阐述的内容。

```
shell@hwmt7:/system/framework $ ls
ls
am.jar
am.odex
android.policy.jar
android.policy.odex
android.test.runner.jar
android.test.runner.odex
apache-xml.jar
apache-xml.odex
bmgr.jar
bmgr.odex
bouncycastle.jar
bouncycastle.odex
bu.jar
bu.odex
com.android.contacts.separated.jar
com.android.contacts.separated.odex
```

▲图2-21　系统目录system/framework下的文件列表

ODEX是Optimized Dalvik Executable的缩写，从字面意思上理解，就是经过优化的Dalvik可执行文件。Dalvik是Android系统（目前已经切换到Art虚拟机）中采用的一种虚拟机，因而经过优化的ODEX文件让我们很自然地想到可以为虚拟机的运行带来好处。

事实上也的确如此——ODEX是Google为了提高Android运行效率做出努力的成果之一。我们知道，Android系统中不少代码是使用Java语言编写的。编译系统首先会将一个Java文件编译成class的形式，进而再通过一个名为dx的工具来转换成dex文件，最后将dex和资源等文件压缩成zip格式的APK文件。换句话说，一个典型的Android APK的组成结构如图2-23所示。

▲图2-22　系统目录/system/app下的文件列表

APK 组成结构
.dex 文件
Resource(.arsc)
Resource（未经处理的资源文件）
AndroidManifest.xml

▲图2-23　APK的组成结构

本书的Android应用程序编译和打包章节将做更为详细介绍。现在大家只要知道APK中有哪些组成元素就可以了。当应用程序启动时，系统需要提取图2-23中的dex（如果之前没有做过ODEX优化的话，或者/data/dalvik-cache中没有对应的ODEX缓存），然后才能执行加载动作。而ODEX则是预先将DEX提取出来，并针对当前具体设备做了优化工作后的产物，这样做除了能提高加载速度外，还有如下几个优势：

- 加大了破解程序的难度

ODEX是在dex基础上针对当前具体设备所做的优化，因而它和生成时所处的具体设备有很大关联。换句话说，除非破解者能提供与ODEX生成时相匹配的环境文件（比如core.jar、ext.jar、framework.jar、services.jar等），否则很难完成破解工作。这就在无形中提高了系统的安全性。

- 节省了存储空间

按照Android系统以前的做法，不仅APK中需要存放一个dex文件，而且/data/dalvik-cache目录下也会有一个dex文件，这样显然会浪费一定的存储空间。相比之下，ODEX只有一份，而且它比dex所占的体积更小，因而自然可以为系统节省更多的存储空间。

2.7 OTA系统升级

前面我们讨论了系统包烧录的几种传统方法，而Android系统其实还提供了另一种全新 的升级方案，即OTA（Over the Air）。OTA非常灵活，它既可以实现完整的版本升级，也可以做到增量升级。另外，用户既可以选择通过SD卡来做本地升级，也可以直接采用网络在线升级。

不论是哪种升级形式，都可以总结为3个阶段：

- 生成升级包；
- 获取升级包；
- 执行升级过程。

下面我们来逐一分析这3个阶段。

2.7.1 生成升级包

升级包也是由系统编译生成的，其编译过程本质上和普通Android系统编译并没有太大区别。如果想生成完整的升级包，具体命令如下：

```
$make otapackage
```

注意

生成OTA包的前提是，我们已经成功编译生成了系统映像文件（system.img等）。

最终将生成以下文件：

```
out/target/product/[YOUR_PRODUCT_NAME]/[YOUR_PRODUCT_NAME]-ota-en
```

而生成差分包的过程相对麻烦一些，不过方法也很多。以下给出一种常用的方式：

- 将上一次生成的完整升级包复制并更名到某个目录下，如～/OTA_DIFF/old_target_file.zip；

- 对源文件进行修改后，用make otapackage编译出一个新的OTA版本；

- 将本次生成的OTA包更名后复制到和上一个升级包相同的目录下，如～/OTA_DIFF/ new_target_file.zip；

- 调用ota_from_target_files脚本来生成最终的差分包。

这个脚本位于：

```
build/tools/releasetools/ota_from_target_files
```

值得一提的是，完整升级包的生成过程其实也使用了这一脚本。区分的关键就在于使用时是否提供了-i参数。

其具体语法格式是：

```
ota_from_target_files [Flags] input_target_files output_ota_packa
```

所有Flags参数释义如表2-9所示。

表2-9　ota_from_target_files参数

参　数	说　明
-b (--board_config) <file>	在新版本中已经无效
-k (--package_key) <key>	<key>用于包的签名默认使用input_target-files中的META/misc_info.txt文件如果此文件不存在，则使用build/target/product/security/testkey
-i (--	

incremental_from) <file>	该选项用于生成差分包
-w (--wipe_user_data)	由此生成的OTA包在安装时会自动擦除user data 分区
-n (--no_prereq)	忽略时间戳检查
-e (--extra_script) <file>	将<file>内容插入update脚本的尾部
-a (--aslr_mode) <on|off>	是否开启ASLR技术默认为开

在这个例子中，我们可以采用以下命令生成一个OTA差分包：

```
./build/tools/releasetools/ota_from_target_files-i ～/OTA_DIFF/old
```

这样生成的update.zip就是最终可用的差分升级包。一方面，差分升级包体积较小，传输方便；但另一方面，它对升级的设备有严格要求，即必须是安装了上一升级包版本的那些设备才能正常使用本次的OTA差分包。

2.7.2　获取升级包

如图2-24所示，有两种常见的渠道可以获取到OTA升级包，分别是在线升级和本地升级。

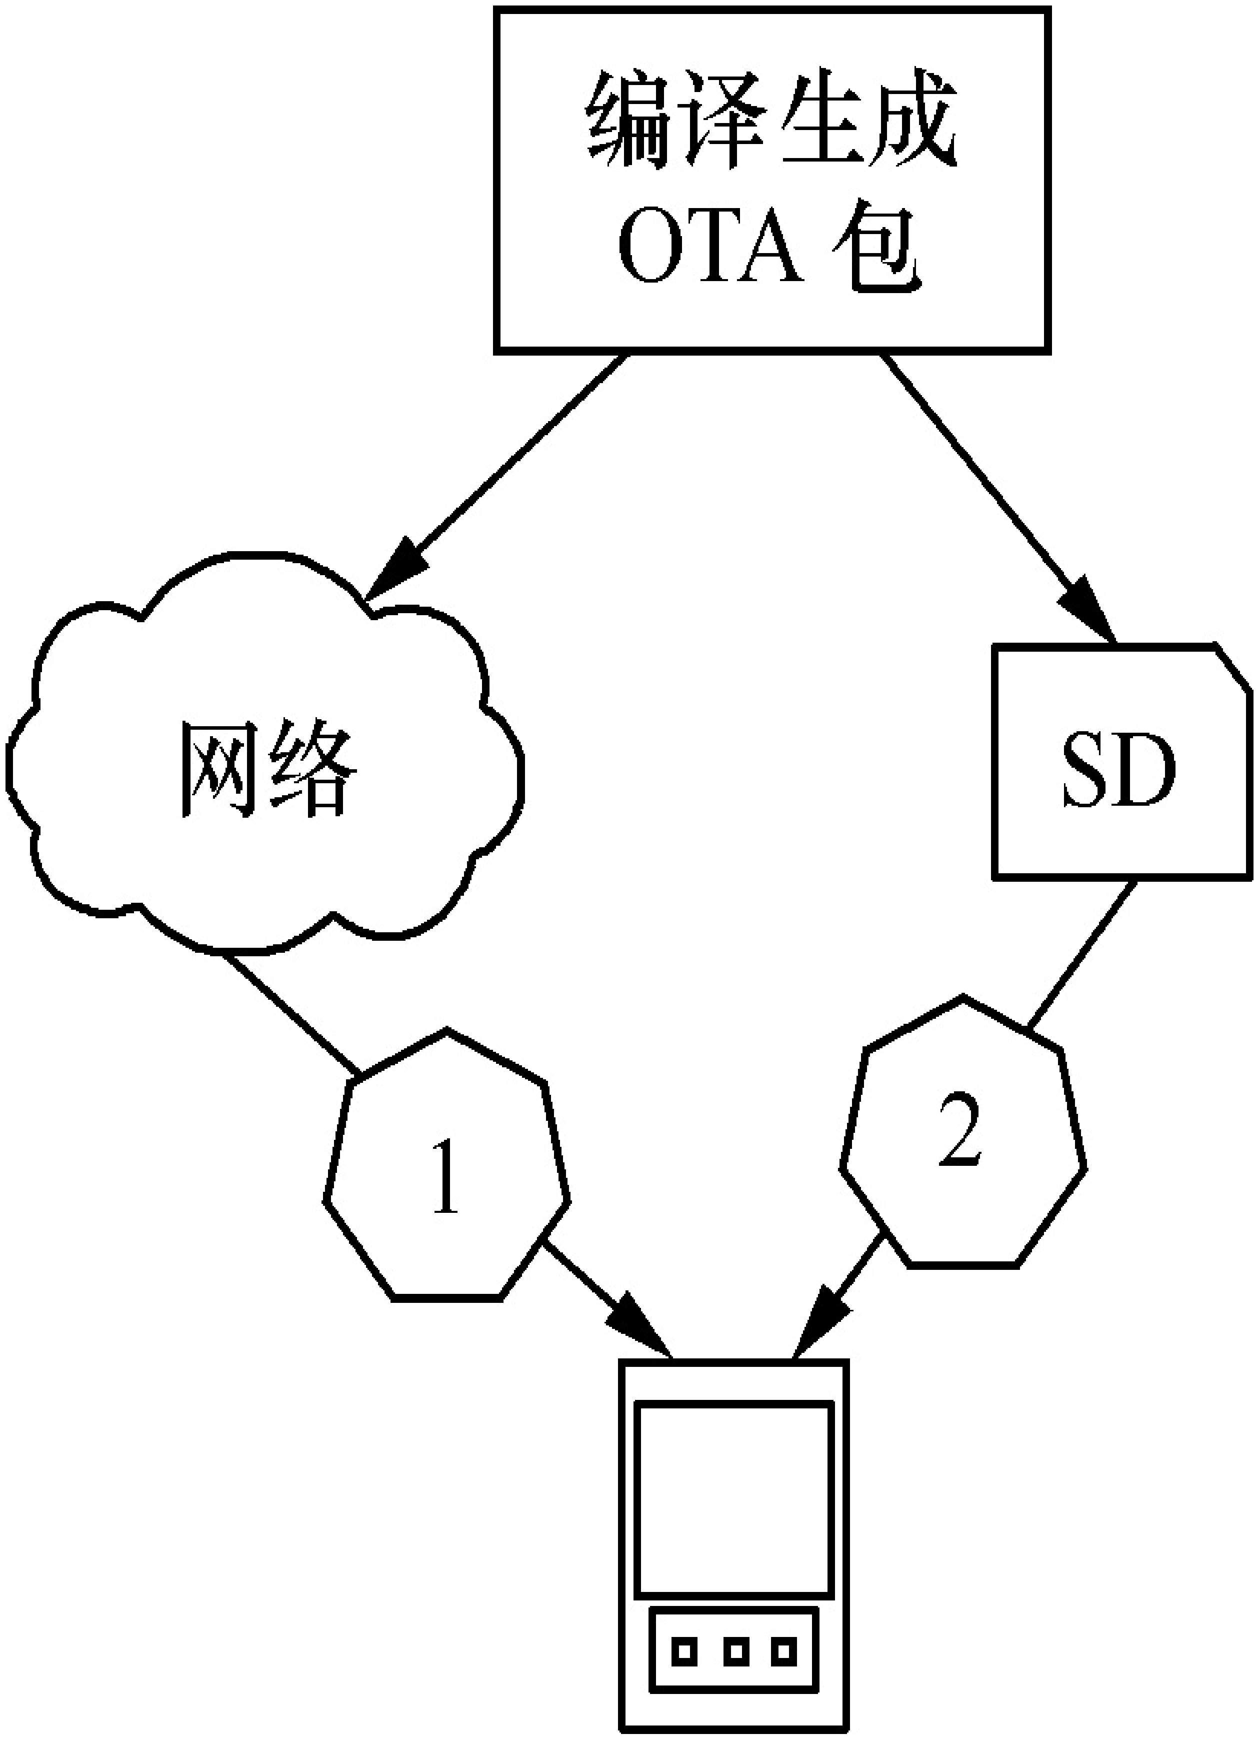
编译生成
OTA 包
网络
SD
1
2

▲图2-24　获取OTA升级包的两种方式

1．在线升级

开发者将编译生成的OTA包上传至网络存储服务器上，然后用户可以直接通过终端访问和下载升级文件。通常我们把下载到的OTA包存储在设备的SD卡中。

在线升级的方式涉及两个核心因素。

- 服务器端的架构

设备厂商需要架构服务器来存放、管理OTA包，并为客户端提供包括查询在内的多项服务。

- 客户端与服务器的交互方式

客户终端如何与服务器进行交互，是否需要认证，OTA包如何传输等都是需要考虑的。

由此可见，在线升级方式要求厂商提供较好的硬件环境来解决用户大规模升级时可能引发的问题，因而成本较高。不过这种方式对消费者来说比较方便，而且可以实时掌握版本的最新动态，所以对凝聚客户有很大帮助。目前很多主流设备生产商（如HTC）和第三方的ROM开发商（如MIUI）都提供了在线升级模式。

服务器和客户端的一种理论交互方案可以参见图2-25所示的图例。

步骤如下：

- 在手动升级的情况下，由用户发出升级的指令；而在自动升级的情况下，则由程序根据一定的预设条件来启动升级流程。比如设定了开机自动检查是否有可用的更新，那么每次机器启动后都会去服务器取得最新的版本信息。
- 无论是手动还是自动升级，都必须通过服务器查询信息。与服务器的连接方式是多种多样的，由开发人员自行决定。在必要的情

况下，还应该使用加密连接。

- 如果一切顺利，我们就得到了服务器上最新升级文件的版本号。接下来需要将这个版本号与本地安装的系统版本号进行比较，决定是否进入下一步操作。

- 如果服务器上的升级文件要比本地系统新（在制定版本号规则时，应尽量考虑如何可以保证新旧版本的快速比较），那么升级继续；否则中止升级流程——且若是手动升级的情况，一定要提示用户中止的原因，避免造成不好的用户体验。

- 升级文件一般都比较大（Android系统文件可能达到几百MB）。这么大的数据量，如果是通过移动通信网络（GSM\WCDMA\CDMA\TD-SCDMA等）来下载，往往不现实。因此如果没有事先知会用户而自动下载的话，很可能会引起用户的不满。“提示框”的设计也要尽可能便利，如可以让用户快捷地启用Wi-Fi通道进行下载。

- 下载后的升级文件需要存储在本地设备中才能进入下一步的升级。通常这一文件会直接被放置在SD卡的根目录下，命名为update.zip。

- 接下来系统将自动重启，并进入RecoveryMode进行升级。

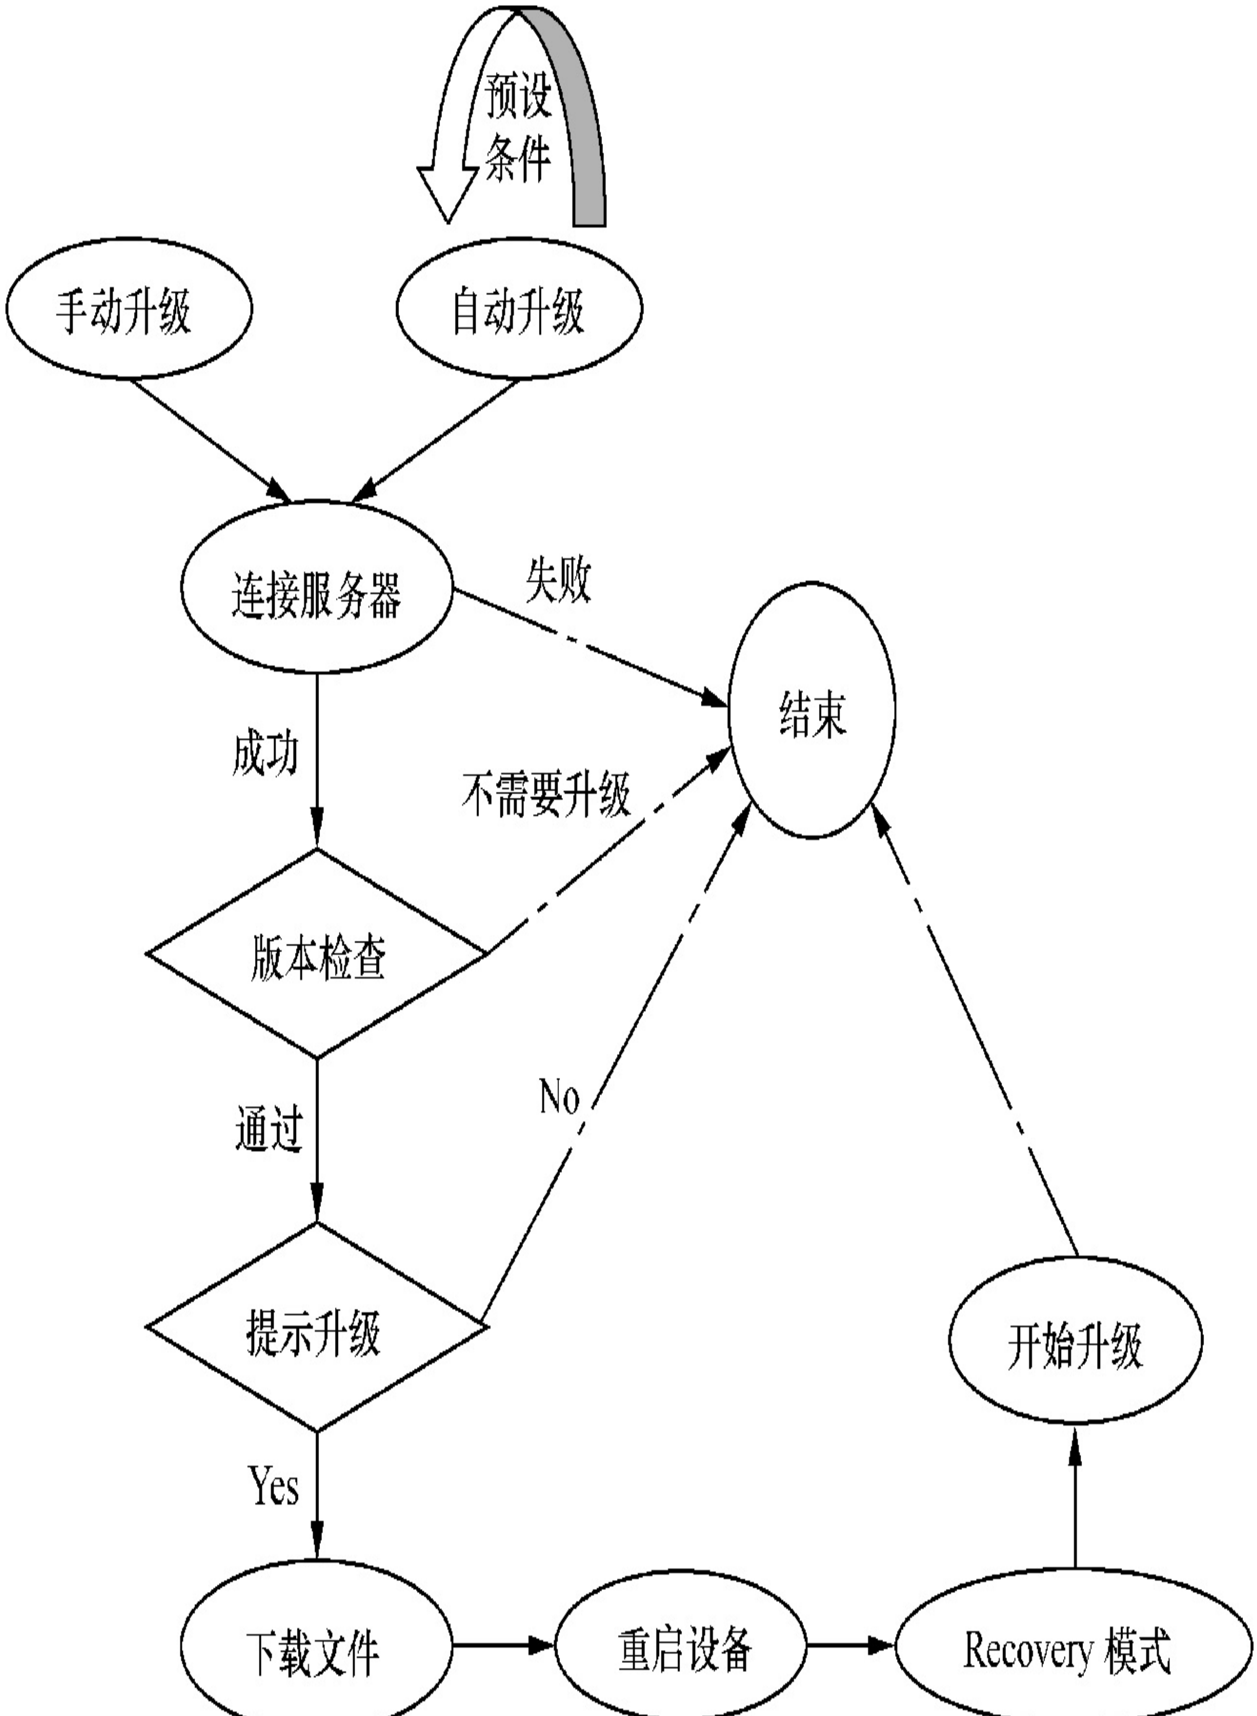
预设
条件
手动升级
自动升级
连接服务器
失败
结束
成功
不需要升级
版本检查
通过
No
提示升级
开始升级
Yes
下载文件
重启设备
Recovery 模式

▲图2-25　在线升级图例

2. 本地升级

OTA升级包并非一定要通过网络在线的方式才可以下载到——只要条件允许，就可以从其他渠道获取到升级文件update.zip，并复制到SD卡的根目录下，然后手动进入升级模式（见下一小节）。

在线升级和本地升级各有利弊，开发商应根据实际情况来提供最佳的升级方式。

2.7.3 OTA升级——Recovery模式

经过前面小节的讲解，现在我们已经准备好系统升级文件了（不论是在线还是本地升级），接下来就进入OTA升级最关键的阶段——Recovery模式，也就是大家俗称的“卡刷”。

Recovery相关的源码主要在工程项目的如下目录中：

\bootable\recovery

因为涉及的模块比较多，这个文件夹显得有点杂乱。我们只挑选与Recovery刷机有关联的部分来进行重点分析。

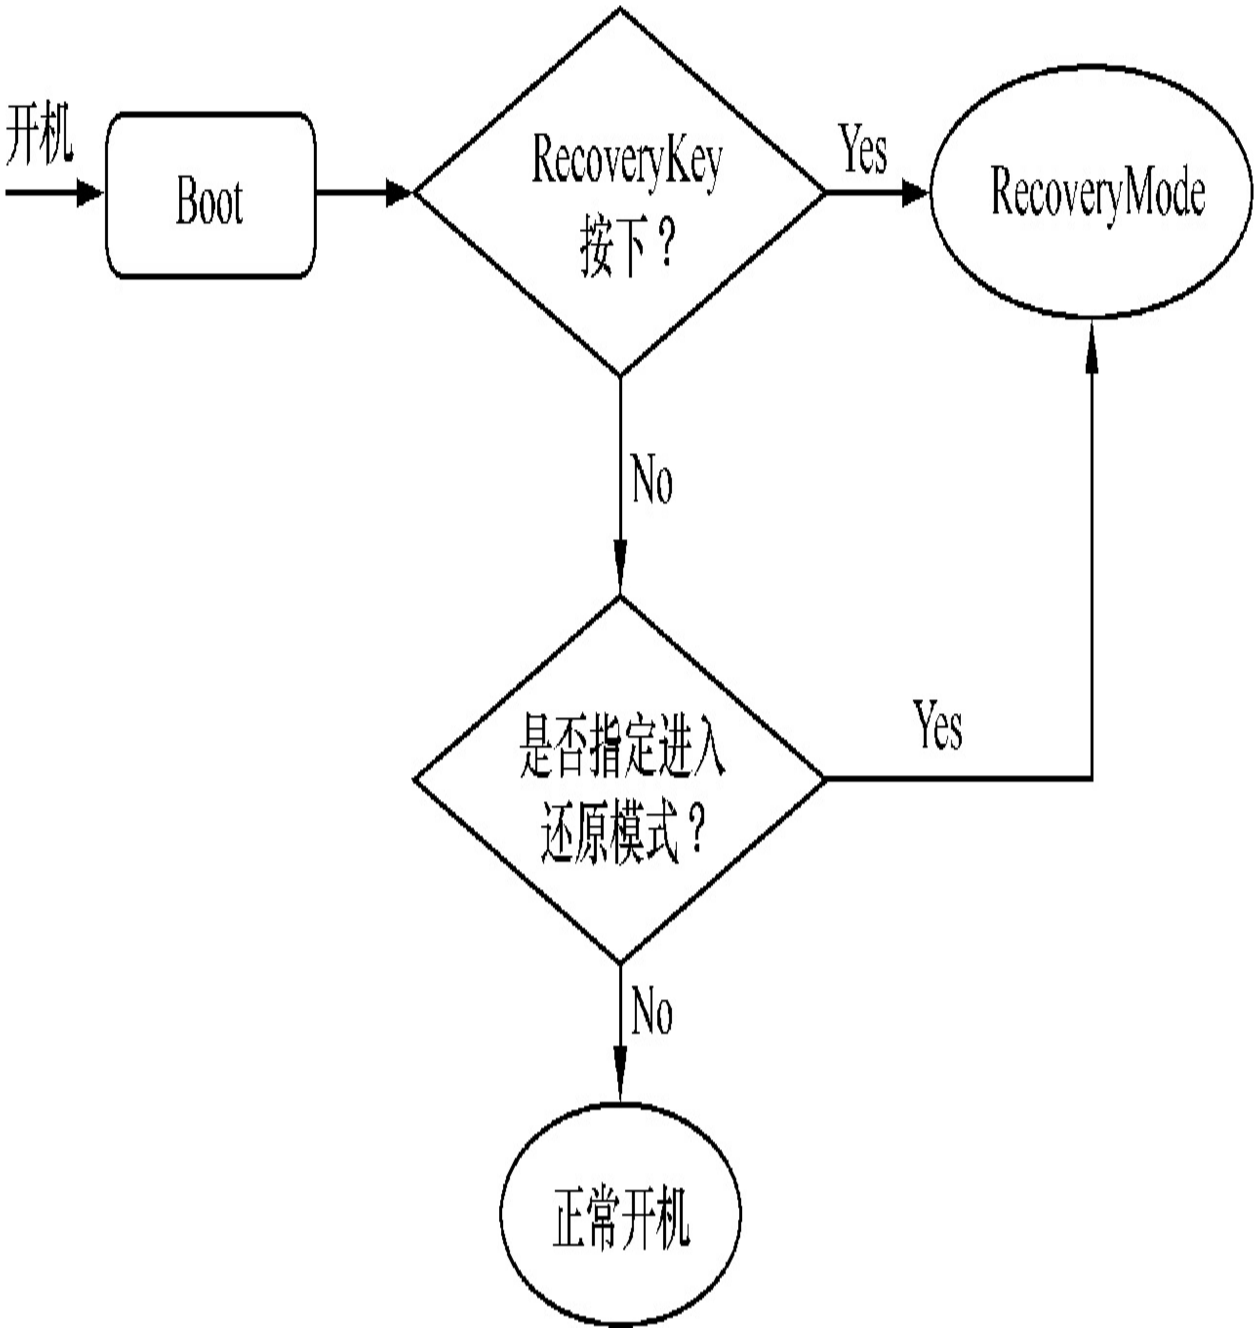

▲图2-26　进入RecoveryMode的流程

图2-26所示是Android系统进入RecoveryMode的判断流程，可见在如下两种情况下设备会进入还原模式。

- 开机过程中检测到RecoveryKey按下

很多Android设备的RecoveryKey都是电源和Volume+的组合键，因

为这两个按键在大部分设备上都是存在的。

- 系统指定进入RecoveryMode

系统在某些情况下会主动要求进入还原模式，如我们前面讨论的“在线升级”方式——当OTA包下载完成后，系统需要重启然后进入RecoveryMode进行文件的刷写。

当进入RecoveryMode后，设备会运行一个名为“Recovery”的程序。这个程序对应的主要源码文件是/bootable/recovery/recovery.cpp，并且通过如下几个文件与Android主系统进行沟通。

（1）/cache/recovery/command　　INPUT

Android系统发送给recovery的命令行文件，具体命令格式见后面的表格。

（2）/cache/recovery/log　OUTPUT

recovery程序输出的log文件。

（3）/cache/recovery/intent　OUTPUT

recovery传递给Android的intent。

当Android系统希望开机进入还原模式时，它会在/cache/recovery/command中描述需要由Recovery程序完成的“任务”。后续Recovery程序通过解析这个文件就可以知道系统的“意图”，如表2-10所示。

表2-10　CommandLine参数释义

Command Line	**Description**
--send_intent=anystring	将text输出到recovery.intent中

--update_package=path	安装OTA包
--wipe_data	擦除user data，然后重启
--wipe_cache	擦除cache（不包括user data），然后重启
--set_encrypted_filesystem=on|off	enable/disable加密文件系统
--just_exit	直接退出，然后重启

由表格所示的参数可以知道Recovery不但负责OTA的升级，而且也是“恢复出厂设置”的实际执行者，如图2-27所示。

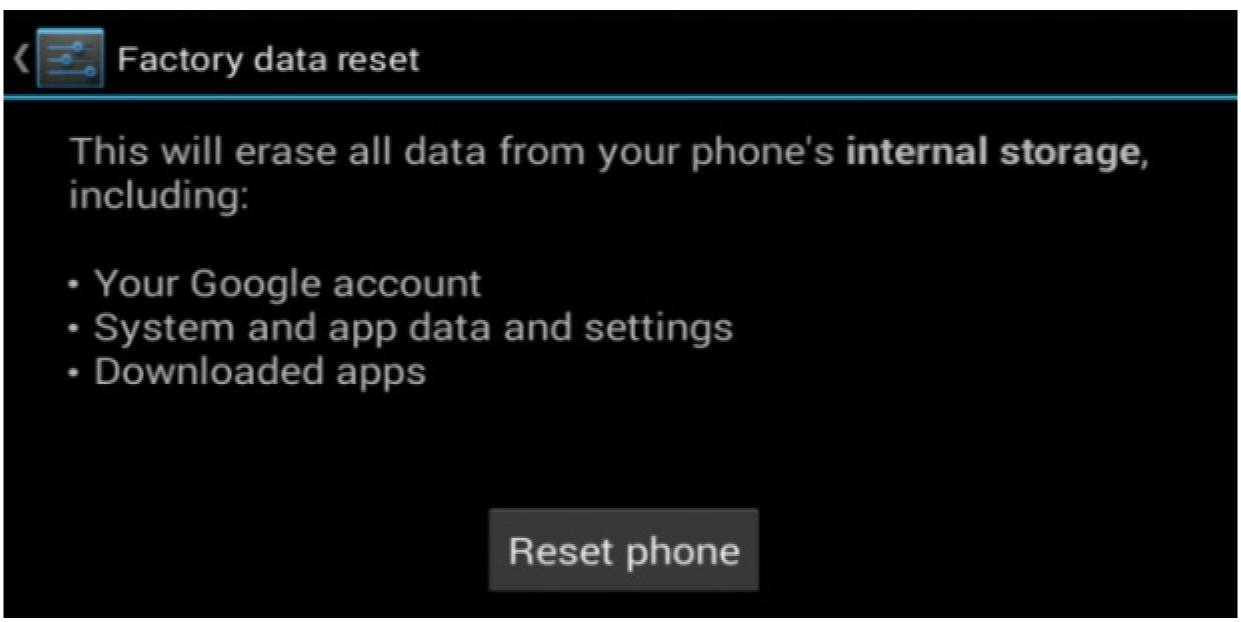

▲图2-27　系统设置中的“恢复出厂设置”

接下来分别讲解这两个功能在Recovery程序中的处理流程。

恢复出厂设置。

（1）用户在系统设置中选择了“恢复出厂设置”。

（2）Android系统在/cache/recovery/command中写入“--wipe_data”。

（3）设备重启后发现了command命令，于是进入recovery。

（4）recovery将在BCB（bootloader control block）中写入“boot-recovery”和“--wipe_data”，具体是在get_args()函数中——这样即便设备此时重启，也会再进入erase流程。

（5）通过erase_volume来重新格式化/data。

（6）通过erase_volume来重新格式化/cache。

（7）finish_recovery将擦除BCB，这样设备重启后就能进入正常的开机流程了。

（8）main函数调用reboot来重启。

上述过程中的BCB是专门用于recovery和bootloader间互相通信的一个flash块，包含了如下信息：

```
struct bootloader_message {
    char command[32];
    char status[32];
    char recovery[1024];
};
```

依据前面对Android系统几大分区的讲解，BCB数据应该存放在哪个image中呢？没错，是misc。

OTA升级具体如下。

（1）OTA包的下载过程参见前一小节的介绍。假设包名是update.zip，存储在SDCard中。

（2）系统在/cache/recovery/command中写入"--update_package=

[路径名]"。

（3）系统重启后检测到command命令，因而进入recovery。

（4）get_args将在BCB中写入"boot-recovery" 和 "--update_package=..." —— 这样即便此时设备重启，也会尝试重新安装OTA升级包。

（5）install_package开始安装OTA升级包。

（6）finish_recovery擦除BCB，这样设备重启后就可以进入正常的开机流程了。

（7）如果install失败的话：

- prompt_and_wait显示错误，并等待用户响应；
- 用户重启（比如拔掉电池等方式）。

（8）main调用maybe_install_firmware_update，OTA包中还可能包含radio/hboot firmware的更新，具体过程略。

（9）main调用reboot重启系统。

总体来说，整个Recovery.cpp源文件的逻辑层次比较清晰，读者可以基于上述流程的描述来对照并阅读代码。

2.8 Android反编译

目前我们已经学习了Android原生态系统及定制产品的编译和烧录过程。和编译相对的，却同样重要的是反编译。比如，一个优秀的“用毒”高手往往也会是卓越的“解毒”大师，反之亦然。大自然的一个奇妙之处即万事万物都是“相生相克”的，只有在竞争中才能不断地进步和发展。

首先要纠正不少读者可能会持有的观点——“反编译”就是去“破解”软件。应该说，破解一款软件的确需要用到很多反编译的知识，不过这并不是它的全部用途。比如笔者就曾经在开发过程中利用反编译辅助解决了一个bug，在这里和读者分享一下。

问题是这样的：开发人员A修改了framework中的某个文件，然后通过正常的编译过程生成了image，再将其烧录到了机器上。但奇怪的是，文件的修改并没有体现出来（连新加的log也没有打印出来）。显然，出现问题的可能是下列步骤中的任何一个，如图2-28所示。

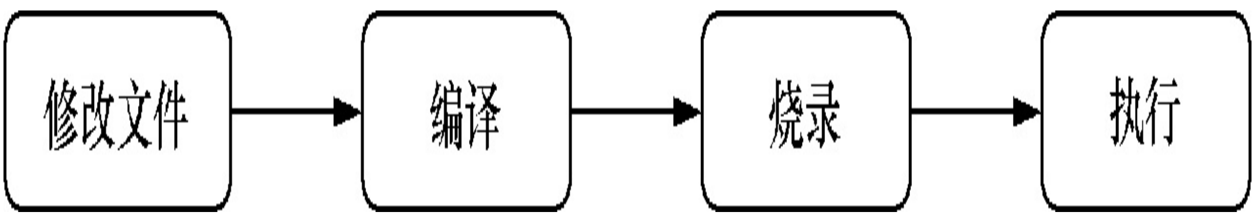

▲图2-28　可能出现问题的几个步骤

可疑点为：

- 程序没有执行到打印log的地方

因为加log的那个函数是系统会频繁调用到的，而且log就放在函数开头没有加任何判断，所以这个可能性被排除。

- log被屏蔽

打印log所用的方法与此文件中其他地方所用的方法完全一致，而且其他地方的log确实成功输出了，所以也排除这一可能性。

- 修改的文件没有被编译到

虽然Android的编译系统非常强大，但是难免会有bug，因而这个可能性还是存在的。那么如何确定我们修改的文件真的被编译到了呢？此时反编译就有了用武之地了。

- 文件确实被编译到，但是烧录时出现了问题

这并不是空穴来风，确实发生过开发人员因为粗心大意烧错版本的“事故”（对于某些细微修改，编译系统不会主动产生新的版本号）。通过反编译机器上的程序，然后和原始文件进行比较，我们可以清楚地确认机器中运行的程序是不是预期的版本。

由上述分析可知，反编译是确定该问题最直接的方式。

Android反编译过程按照目标的不同分为如下两类（都是基于Java语言的情况）。

- APK应用程序包的反编译。
- Android系统包（如本例中的framework）的反编译。

不论针对哪种目标对象，它们的步骤都可以归纳为如图2-29所示。

APK应用安装包实际上是一个Zip压缩包，使用Zip或WinRAR等软件打开后里面有一个“classes.dex”文件—— 这是Dalvik JVM虚拟机支持的可执行文件（Dalvik Executable）。关于这个文件的生成过程，可以参见本书应用篇中对APK编译过程的介绍。换句话说，classes.dex这个文件包含了所有的可执行代码。

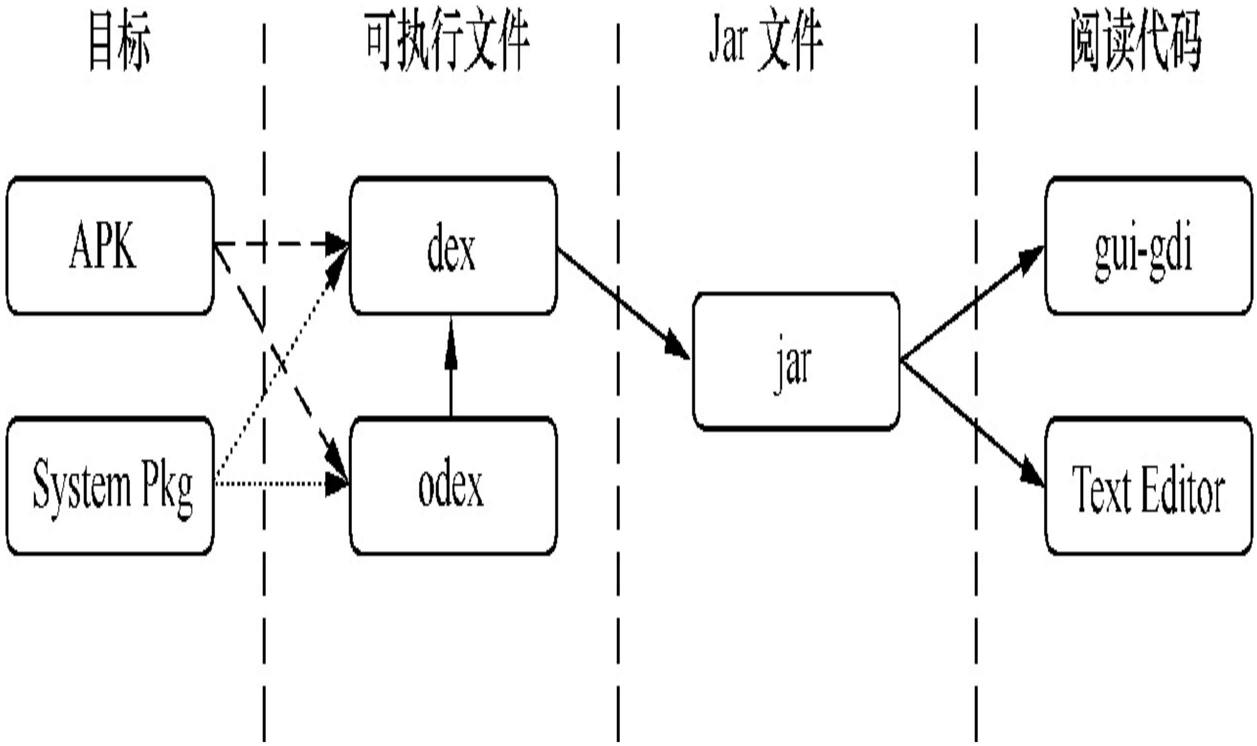

▲图2-29　反编译的一般流程

由前面小节的学习我们知道，odex是classes.dex经过dex优化（optimize）后产生的。一方面，Dalvik虚拟机会根据运行需求对程序进行合理优化，并缓存结果；另一方面，因为可以直接访问到程序的odex，而不是通过解压缩包去获取数据，所以无形中加快了系统开机及程序的运行速度。

针对反编译过程，我们首先是要取得程序的dex或者odex文件。如果是APK应用程序，只需要使用Zip工具解压缩出其中的classes.dex即可（有的APK原始的classes.dex会被删除，只保留对应的odex文件）；而如果是包含在系统image中的系统包（如framework就是在system.img中），就需要通过其他方法间接地将其原始文件还原出来。具体步骤可以参见前一小节的介绍。

取得dex/odex文件后，我们将它转化成Jar文件。

- odex

目前已经有不少研究项目在分析Android的逆向工程，其中最著名的就是smali/baksmali。可以在这里下载到它的最新版本：

http://code.google.com/p/smali/downloads/list

“smali”和“baksmali”分别对应冰岛语中“assembler”和“disassembler”。为什么要用冰岛语命名呢？答案就是Dalvik这个名字实际上是冰岛的一个小渔村。

如果是odex，需要先用baksmali将其转换成dex。具体语法如下：

```
$ baksmali -a <api_level> -x <odex_file> -d <framework_dir>
```

-a指定了API Level，-x表示目标odex文件，-d指明了framework路径。因为这个工具需要用到诸如core.jar，ext.jar，framework.jar等一系列framework包，所以建议读者直接在Android源码工程中out目录下的system/framework中进行操作，或者把所需文件统一复制到同一个目录下。

范例如下（1.4.1版本）：

```
$ java -jar  baksmali-1.4.1.jar  -a 16  -x  example.odex
```

如果是要反编译系统包中的odex（如services.odex），请参考以下命令：

```
$java -Xmx512m -jar baksmali-1.4.1.jar -a 16 -c:core.jar:bouncyca
jar:android.policy.jar:services.jar:core-junit.jar -d framework/
```

更多语法规则可以通过以下命令获取：

```
$ java -jar  baksmali-1.4.1.jar  --help
```

执行结果会被保存在一个out目录中，里面包含了与odex相应的所有源码，只不过由smali语法描述。读者如果有兴趣的话，可以阅读以下文档来了解smali语法：

http://code.google.com/p/smali/wiki/TypesMethodsAndFields

当然对于大部分开发人员来说，还是希望能反编译出最原始的Java语言文件。此时就要再将smali文件转化成dex文件。具体命令如下：

```
$ java -jar  smali-1.4.1.jar out/ -o  services.dex
```

于是接下来的流程就是dex→Java，请参考下面的说明。

- dex

前面我们已经成功将odex“去优化”成dex了，离胜利还有一步之遥——将dex转化成jar文件。目前比较流行的工具是dex2jar，可以在这里下载到它的最新版本：

http://code.google.com/p/dex2jar/downloads/list

使用方法也很简单，具体范例如下：

```
$ ./dex2jar.sh  services.dex
```

上面的命令将生成services_dex2jar.jar，这个Jar包中包含的就是我们想要的原始Java文件。那么，选择什么工具来阅读Jar中的内容呢？在本例中，我们只是希望确定所加的log是否被正确编译进目标文件中，因而可以使用任何常用的文本编辑器查阅代码。而如果希望能更方便地阅读代码，推荐使用jd-gui，它是一款图形化的反编译代码阅读工具。

这样，整个反编译过程就完成了。

顺便提一下，目前，几乎所有的Android程序在编译时都使用了“代码混淆”技术，反编译后的结果和原始代码还是有一定差距，但不影响我们理解程序的主体架构。“代码混淆”可以有效地保护知识产权，防止某些不法分子恶意剽窃，或者篡改源码（如添加广告代码、植入木马等），建议大家在实际的项目开发中尽量采用。

2.9 NDK Build

我们知道Android系统下的应用程序主要是由Java语言开发的，但这并不代表它不支持其他语言，比如C++和C。事实上，不同类型的应用程序对编程语言的诉求是有区别的——普通Application的UI界面基本上是静态的，所以，利用Java开发更有优势；而游戏程序，以及其他需要基于OpenGL（或基于各种Game Engine）来绘制动态界面的应用程序则更适合采用C或者C++语言。

伴随着Android系统的不断发展，开发者对于C/C++语言的需求越来越多，也使得Google需要不断完善它所提供的NDK工具链。NDK的全称是Native Development Kit，可以有效支撑Android系统中使用C/C++等Native语言进行开发，从而让开发者可以：

- 提高程序运行效率

完成同样的功能，Java虚拟机理论上来说比C/C++要耗费更多的系统资源。因而，如果程序本身对运行性能要求很高的话，建议利用NDK进行开发。

- 复用已有的C和C++库

好处是显而易见，即最大程度地避免重复性开发。

NDK的官方网址是：

https://developer.android.com/ndk/index.html

它的安装很简单，在Windows下只要下载一个几百MB的自解压包然后双击打开它就可以了。NDK文件夹可以被放置到磁盘中的任何位置，不过为了操作方便，建议开发者可以设置系统环境变量来指向其中的关键程序。NDK既支持Java和C/C++混合编程的模式，也允许我们只开发纯Native实现的程序。前者需要用到JNI技术(即Java Native Interface)，它的神奇之处在于可以让两种看似没有瓜葛的语言间进行无缝的调用。例如下面是一个JNI的实例：

```
public class MyActivity extends Activity {
  /**
```

```
  * Native method implemented in C/C++
  */
  public <strong>native</strong> void jniMethodExample();
}
```

MyActivity是一个Java类，它的内部包含一个声明为Native的成员变量，即jniMethodExample。这个函数的实现是通过C/C++完成的，并被编译成so库来供程序加载使用。更多JNI的细节，我们将在后续章节进行详细介绍。

本小节我们将通过一个具体实例来着重讲解如何利用NDK来为应用程序执行C/C++的编译。

在此之前，请确保你已经下载并解压了NDK包，并为它设置了正确的系统环境变量。这个例子中将包含如下几个文件，我们统一放在一个JNI文件夹中：

- Android.mk；
- Application.mk；
- testNative.cpp。

Android.mk用于描述一个Android的模块，包括应用程序、动态库、静态库等。它和我们本章节讲解的用法基本一致，因而不再赘述。

Application.mk用于描述你的程序中所用到的各个Native模块（可以是静态或者动态库，或者可执行程序）。这个脚本中常用的变量不多，我们从中挑选几个核心的来讲解：

1．APP_PROJECT_PATH

指向程序的根目录。当然，如果你是按照Android系统默认的结构来组织工程文件的话，这个变量是可选的。

2．APP_OPTIM

用于指示当前是release或者debug版本。前者是默认的值，将会生成优化程度较高的二进制文件;调试模式则会生成未优化的版本，以便保留更多的信息来帮助开发者追踪问题。在AndroidManifest.xml的<application>标签中声明android:debuggable会将默认值变更为

debug，不过APP_OPTIM的优先级更高，可以重载debuggable的设置。

3．APP_CFLAGS

设置对全体module有效的C/C++编译标志。

4．APP_LDFLAGS

用于描述一系列链接器标志，不过只对动态链接库和可执行程序有效。如果是静态链接库的情况，系统将忽略这个值。

5．APP_ABI

用于指示编译所针对的目标Application Binary Interface，默认值是armeabi。可选值如表2-11所示。

表2-11　可选值

指　令　集	**ABI**值
Hardware FPU instructions on ARMv7 based devices	APP_ABI := armeabi-v7a
ARMv8 AArch64	APP_ABI := arm64-v8a
IA-32	APP_ABI := x86
Intel64	APP_ABI := x86_64
MIPS32	APP_ABI := mips

MIPS64 (r6)	APP_ABI := mips64
All supported instruction sets	APP_ABI := all

文件testNative.cpp中的内容就是程序的源码实现，对此NDK官方提供了较为完整的Samples供大家参考，涵盖了OpenGL、Audio、Std等多个方面，有兴趣的读者可以自行下载分析。

那么有了这些文件后，如何利用NDK把它们编译成最终产物呢？

最简单的方式就是采用如下的命令：

```
cd <project>
$ <ndk>/ndk-build
```

其中ndk-build是一个脚本，等价于：

```
$GNUMAKE -f <ndk>/build/core/build-local.mk
<parameters>
```

<ndk>指的是NDK的安装路径。

可见使用NDK来编译还是相当简单的。另外，除了常规的编译外，ndk-build还支持多种选项，譬如：

“clean”表示清理掉之前编译所产生的各种中间文件；

“-B”会强制发起一次完整的编译流程；

“NDK_LOG=1”用于打开NDK的内部log消息；

……

2.10　第三方ROM的移植

除了本章所描述的Android原生代码外，开发人员也可以选择一些知名的第三方开源ROM来进行学习，譬如CyanogenMod。

CyanogenMod（简称CM）的官方网址如下：

http://www.cyanogenmod.org/

它目前的最新版本是基于Android 6.0的CM 13，并同时支持Google Nexus、HTC、Huawei、LG等多个品牌的众多设备。CyanogenMod的初衷是将Android系统移植到更多的没有得到Google官方支持的设备中，所以有的时候CM针对某特定设备的版本更新时间可能比设备厂商来得还要早。

那么CyanogenMod是如何做到针对多种设备的移植和适配工作的呢?我们将在接下来的内容中为大家揭开这个问题的答案。图2-30是CM的整体描述图。

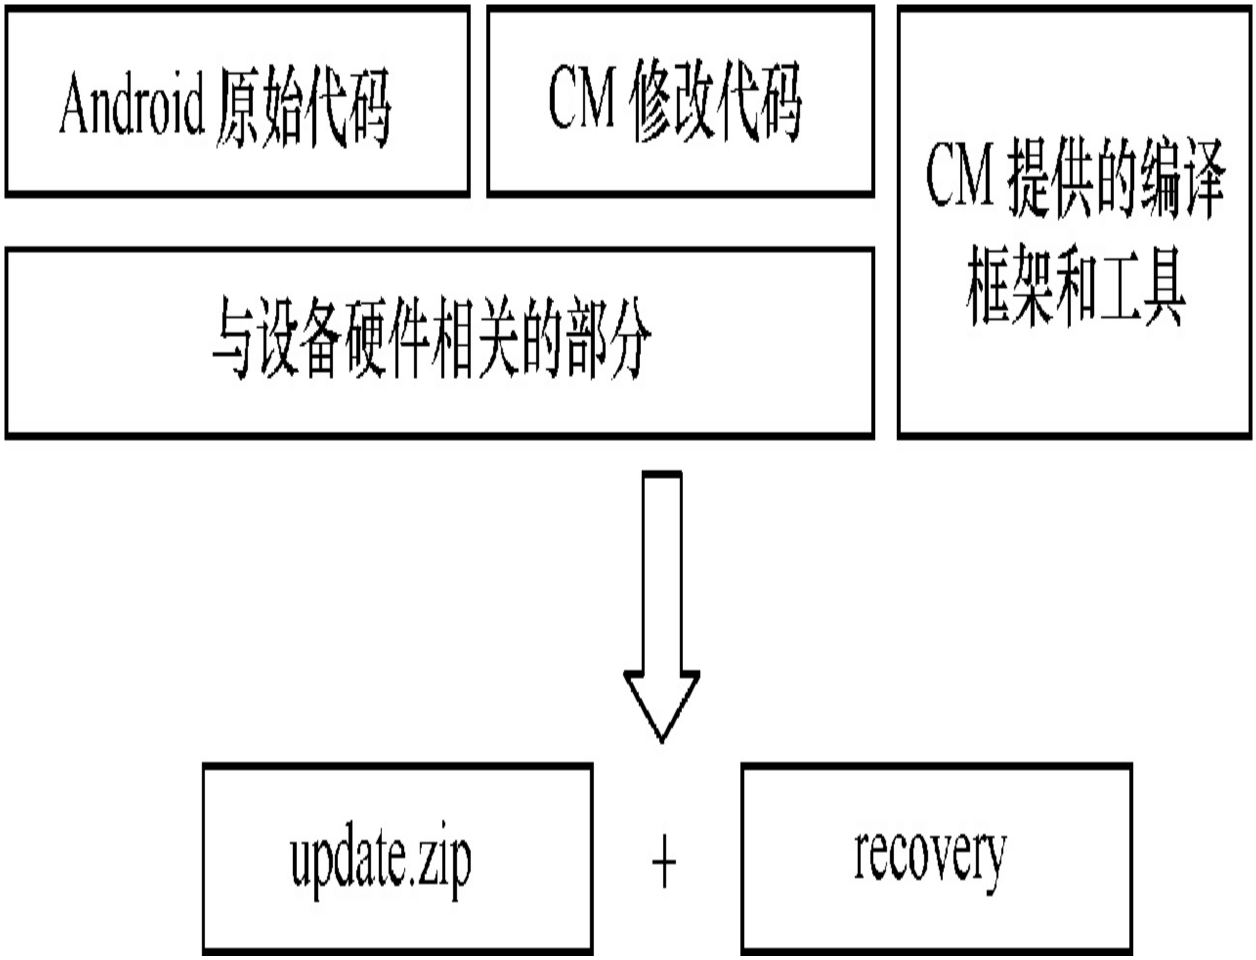

▲图2-30　CM的整体描述

下面我们分步骤进行讲解。

Step1. 前期准备

在做Porting之前，有一些准备工作需要我们去完成。

（1）获取设备的Product Name、Code Name、Platform Architecture、Memory Size、Internal Storage Size等信息

这些数据有很多可以从/system/build.prop文件中获得，不过前提条件是手机需要被root。

（2）收集设备对应的内核源码

根据GPL开源协议的规定，Android厂商必须公布受GPL协议保护的内容，包括内核源码。因而实现这一步是可行的，只是可能会费些周折。

（3）获取设备的分区信息

Step2. 建立3个核心文件夹

分别是：

- device/[vendor]/[codename]/

设备特有的配置和代码将保存在这个路径下。

- vendor/[vendor]/[codename]/

这个文件夹中的内容是从原始设备中拉取出来的，由此可见主要是那些没有源代码可以生成的部分，例如一些二进制文件。

- kernel/[vendor]/[codename]/

专门用于保存内核版本源码的地方。

CM提供了一个名为mkvendor.sh的脚本来帮助创建上述文件夹的“雏形”，有兴趣的读者可以参见build/tools/device/mkvendor.sh文件。不过很多情况下还需要开发者手工修改其中的部分文件，例如device目录下的BoardConfig.mk、device_[codename].mk、cm.mk、recovery.fstab等核心文件。

Step3. 编译一个用于测试的recovery image

编译过程和普通CM编译的最大区别在于选择make recoveryimage。如果在recovery模式下发现Android设备的硬件按键无法使用，那么可以尝试修改/device/[vendor]/[codename]/recovery/recovery_ui.cpp中的GPIO配置。

Step4. 为上述的device目录建立github仓库，以便其他人可以访问到。

Step5. 填充vendor目录

可以参考CM官网上成熟的设备范例提供的extract-files.sh和setup-makefiles.sh，并据此完成适合自己的这两个脚本。

Step6. 通过CM提供的编译命令最终编译出ROM升级包，并利用前面生成的recovery来将其刷入到设备中。这个过程很可能不是“一蹴而就”的，需要不断调试和修改，直至成功。

当然，限于篇幅我们在本小节只是讲解了CM升级包的核心制作过程，读者如果有兴趣的话可以查阅http://www.cyanogenmod.org/来获取更多细节详情。

第3章 Android编译系统

3.1 Makefile入门

如果读者曾在Linux环境下开发过程序，那么对Makefile一定不会陌生。简单而言，Makefile提供了一种机制，让使用者可以有效地组织“工作”。注意这里只使用“工作”这个词，而不是“编译”。这是因为Makefile并不一定是用来完成编译工作。事实上它本身只是一种“规则”的执行者，而使用者具体通过它来做什么则没有任何限制。如既可以用它来架构编译系统，也能用来生成文档，或者单纯地打印log等。

从中可以看出，理解Makefile的“规则”才是我们学习的重点。只要学会了“渔”，自然就什么“鱼”都不缺了。

和shell、python等类似，Makefile也是一个脚本，由make程序来解析。目前软件行业有多款优秀的make解析程序，如GNU make（Android中采用的）、Visual Studio中的nmake等。尽管在表现形式上会有些差异，但“万变不离其宗”，它们都是通过以下基础规则扩展起来的：

```
TARGET: PREREQUISITES
    COMMANDS
```

注意

每个COMMAND前都必须有一个TAB制表符。

这个看起来简单得不能再简单的规则，在经过一次次的扩展修饰后，便构建成最终我们看到的各种庞大工程的编译系统。在Makefile规则中，TARGET是需要生成的目标文件，PREREQUISITES代表了目标所依赖的所有文件。当PREREQUISITES文件中有任何一个比TARGET新时，那么都会触发下面COMMAND命令的执行。COMMAND的具体内容取决于使用者的需求，如调用GCC编译器、生成某个文档等。

下面我们通过一个简单的例子（Linux环境下，采用GCC编译器来生成一个可运行程序）来讲解这个规则的使用方法。

范例项目包括的主要工程文件和说明如表3-1所示。

表3-1　工程文件和说明

文件名	描述
main.c	主函数所在文件
utility.h	提供了一个测试函数（getNumber）的声明
utility.c	提供了函数getNumber的实现。getNumber函数只是简单地返回一个值，没有其他特别的功能
Makefile	用于编译整个工程

我们先来看一下各工程文件中主要的源码节选。

（1）main.c中将打印一条语句，输出getNumber()函数的返回值。

```
1  #include <stdio.h>
2  #include "utility.h"
3
4  int main(int argc, char *argv[])
5  {
6      printf("Hello, getNumber=%d\n", getNumber());
7      return 0;
8  }
9
```

（2）utility.h中，仅仅是对getNumber进行了函数声明。

```
1  int getNumber();
2
```

（3）utility.c中，给出了getNumber的函数实现。

```
1  #include "utility.h"
2
3  int getNumber()
4  {
5      return 2;
6  }
7
```

（4）Makefile文件，是编译过程的“规划者”。

```
1  SimpleMakefile:main.o utility.o
2      gcc -o SimpleMakefile main.o utility.o
3
4  main.o:main.c
5      gcc -c main.c
6
7  utility.o:utility.c
8      gcc -c utility.c
9
10
```

根据前面提到的“基础规则”，这个脚本共有3个TARGET，即SimpleMakefile、main.o及utility.o。其中SimpleMakefile依赖于后两者，而main.o和utility.o则又分别由对应的C文件编译生成。

最后我们通过调用make命令来生成SimpleMakefile可执行文件。运

行结果如下：

```
ding/Foundation_Ex01_SimpleMakefile$ ./SimpleMakefile
Hello, getNumber=2
```

这是一个非常简单的Makefile示例，但“麻雀虽小，五脏俱全”，它向我们清晰地展示了一个Makefile的编写过程。Make工具本身是非常强大的，有很多隐含规则来帮助开发者快速构建一个复杂的编译体系。如利用它的自动推导功能，可以简化对象间的依赖关系；还可以加入各种变量以避免多次重复输入。如下面就是SimpleMakefile程序的另一个Makefile版本，和前一个相比显然更简洁明了。

```
1  OBJECT = main.o utility.o
2  
3  SimpleMakefile:$(OBJECT)
4      gcc -o SimpleMakefile $(OBJECT)
5  
6  
```

另外，我们还需要不断熟悉Android编译系统中常见的一些Makefile的高级用法。例如下面这两种。

（1）Target-Specific Variable

这是一种局部作用域的变量，它只对特定的目标起效果。譬如下面这个例子中的PRIVATE_DEX_FILE变量：

```
/*build/core/package_internal.mk*/
ifdef LOCAL_DEX_PREOPT
$(built_odex): <strong>PRIVATE_DEX_FILE</strong> := $(built_dex)
# Use pattern rule - we may have multiple built odex files.
$(built_odex) : $(dir $(LOCAL_BUILT_MODULE))% : $(built_dex)
     $(hide) mkdir -p $(dir $@) && rm -f $@
     $(add-dex-to-package)
     $(hide) mv $@ $@.input
     $(call dexpreopt-one-file,$@.input,$@)
     $(hide) rm $@.input
endif
```

我们知道，Make会首先构建出依赖树，然后才会根据用户选择目标来执行相应的编译操作。换句话说，当Make执行到上述脚本语句时，并不会触发COMMANDS部分的执行。那么如果我们直接在COMMANDS（在这个

场景中，add-dex-to-package会调用到PRIVATE_DEX_FILE）中使用$(built_dex)这种全局变量会发生什么事呢？

因为package_internal.mk是APK编译模板的内部实现（可以参考后续小节的介绍），所以它在整个系统编译过程中会被多次调用。换句话说，$(built_dex)的值是不断在变化中的。而当原先的$(built_odex)在执行自己的COMMANDS时，$(built_dex)的值早已经“物是人非”了，所以，在COMMANDS中直接调用它有可能导致不可预期的错误。例如PRIVATE_DEX_FILE就是属于$(built_odex)规则中的特定私有变量（这也是变量名中“PRIVATE”所表达的含义）。因而，无论外界环境如何变化，PRIVATE_DEX_FILE的值在定义它的目标规则中都是不变的，这样一来就有效保证了编译执行阶段的准确性。

（2）Static Pattern Rules

另一个Android编译脚本中常见的Makefile语法是Static Pattern Rules。它的典型格式中带有两个“:”，如下所示：

```
TARGETS ...: TARGET-PATTERN: DEP-PATTERNS ...
    COMMANDS
```

静态模式语法经常被应用于多目标的场景。如下所示就是一个简单的范例：

```
foo.o tcc.o bar.o : %.o : %.c
```

在这个例子中，TARGET-PATTERN带有一个“%”，它与TARGETS集合中的元素进行匹配，便可以得到词干（STEM）：foo tcc bar;得到的词干再和DEP-PATTERNS中的“%”进行组合，从而为不同目标生成正确的依赖对象（foo.c tcc.c bar.c）。

除此之外，Makefile实际上还有很多高级用法和规则，希望读者能自行查阅相关资料做进一步了解，以便为后续更好地理解Android编译系统打下坚实的基础。

3.2 Android编译系统

很多人在初次分析Android的编译系统时，都会有一种感觉——这是一头让人“胆寒的怪兽”。因为它正好符合怪兽的两个特点，即功力深厚且体积庞大，甚至可以说有点臃肿。这在一定程度上也加重了我们分析它内部结构的难度。就如同漫步在崇山峻岭或深山野林一般，如果缺乏很明确的指引，那么稍有不慎便会迷失方向。

事实上Android编译系统也是经过了数次不断地迭代演进，才成长为今天大家所看到的“怪兽”。特别是在Google收购Android系统不久后的2006年，他们曾对编译系统动过一次“大手术”。核心目标有两个：

- 让依赖关系分析更为可靠，以保证可以正确判断出需要被编译的模块；
- 让不必要被编译的模块也可以被准确判断出来，以提高编译效率。

在那次重构中，Android遵循了多个设计原则和策略，包括但不限于：

（1）同一套代码支持编译出不同的构建目标。例如既可以编译出运行于设备端的软件包，也可以编译出Host平台上的各种工具（模拟器、辅助工具等）。

（2）Non-Recursive Make：1997年的时候有一篇非常有名的论文，名为《Recursive Make Considered Harmful》，其核心思想是我们在大型项目中应该采用唯一的Makefile来组织所有文件的自动化编译，并对比了它和传统的多Makefile的优势。相信这篇论文对当年重构过程起到了很大的影响，可以说直到今天，Android编译系统的主体框架还是采用Non-Recursive的方式。有兴趣的读者可以阅读一下这篇论文。

（3）可以对项目中的任意模块进行单独的编译验证。比如我们只更改了Art虚拟机所对应的libart.so，那么就应该能做到只以这个so库为中心来开展编译工作，而不需要每次都是整个项目编译。

（4）编译所产生的中间过程文件，以及最终的编译结果和源代码

需要在存储目录上分离等。

在本节内容的组织上，我们将采取由上而下、由整体到局部的方式将Android编译系统所涉及的各个重要方面一一理顺。希望通过这种分析手法，让读者可以逐步摸清整个编译机制的内部架构，而不致牵绊于各种宏、函数、变量、目录结构等细枝末节。另外，希望读者在阅读接下来内容的过程中还可以同步思考一下编译系统的几个设计原则具体是如何实现的，以期达到触类旁通的效果。

3.2.1 Makefile依赖树的概念

细心的读者应该已经注意到了，前一小节的SimpleMakefile中各TARGET的依赖关系实际上可以组成一棵树，本书将其称为“Makefile依赖树”。

我们仍以上一小节的工程项目为例，给出它的依赖树，如图3-1所示。

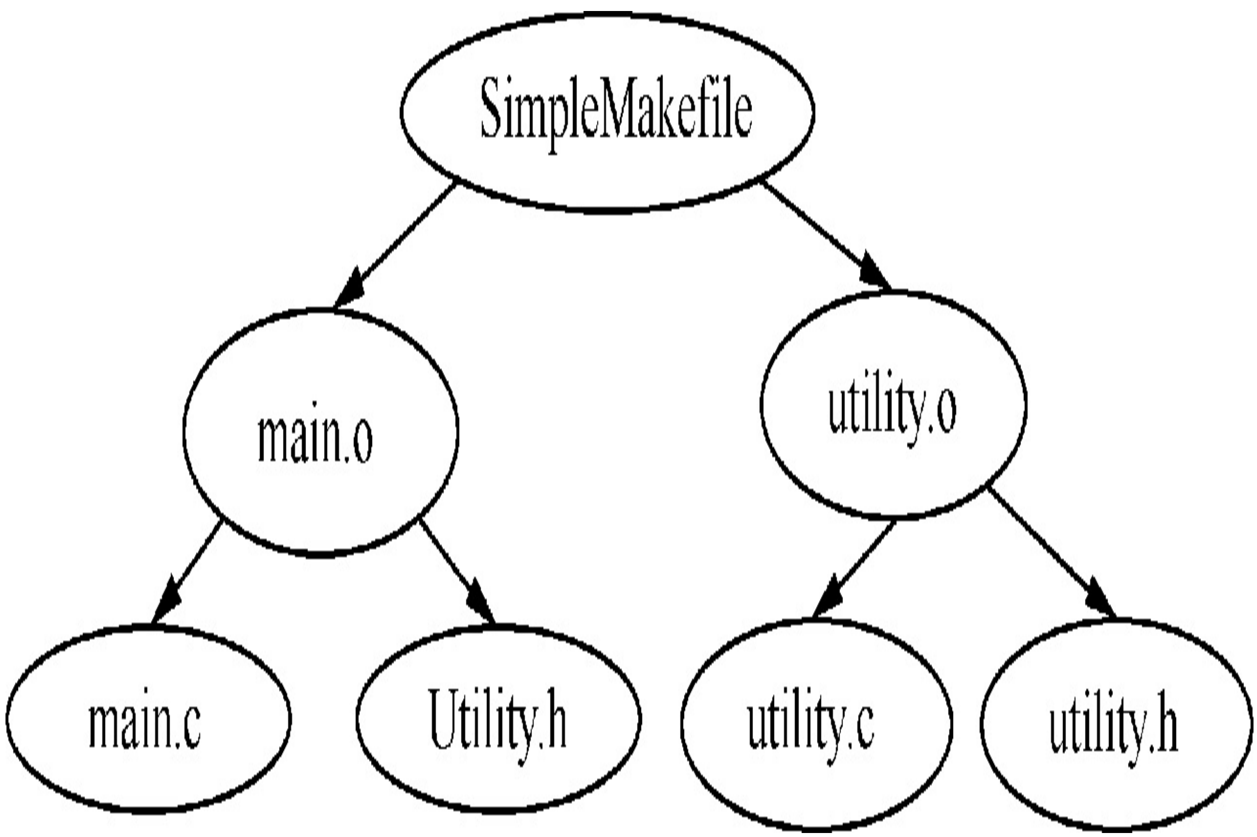

▲图3-1 SimpleMakefile的依赖树

这种树型结构为我们按照由上而下的顺序分析Android编译系统提供了可能，接下来几个小节的内容就是由此展开的。

3.2.2　Android编译系统抽象模型

我们对Android编译系统进行抽象，其顶层模型如图3-2所示。

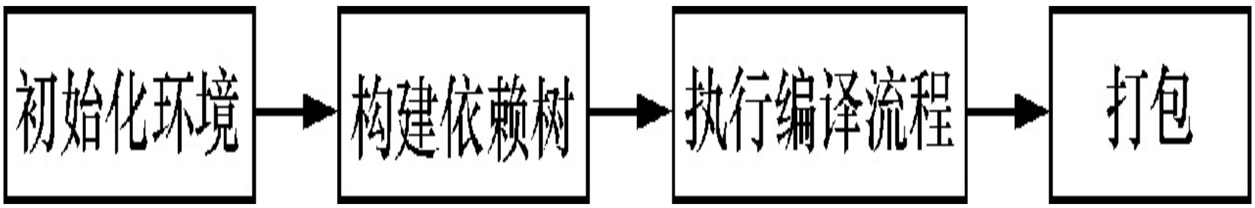

▲图3-2　Android编译系统的抽象模型

因为是基于Makefile实现的，所以，整个编译系统的核心仍然是如何有效地构建出依赖树；Android系统的编译过程涉及Java、C/C++等多种语言，而且还分为Host和Target等不同的目标平台，因而它的运行环境相对复杂，需要我们在初始化环节做好环境的搭建工作（例如当前的JDK和Make的版本是否满足要求）；编译的执行过程本质上和传统的Make实现没有太大差异，只不过因为Android工程非常庞大，所以初学者往往很难在短时间内全部掌握；编译系统的另一个重要任务则是打包，包括system.img、boot.img、userdata.img等，我们在后续小节会有更深入的分析。

3.2.3　树根节点droid

树根节点一定是整个编译系统的最终目标产物吗？

答案既可能是肯定的，也可能是否定的。

肯定的一面，是因为有些树根节点（比如SimpleMakefile）确实是整个工程项目的“目标产物”——它是真实存在的“生成物”；而更多情况下，特别是对Android系统这种庞然大物而言，它的树根节点往往只是一个“伪目标”——它的确是代表了编译系统的“终极目标意愿”，本身却不是一个真正的“TARGET”。

我们先从Android源码工程的根目录分析起，其下的Makefile文件

是其编译系统的起点。可以看到，它只是一个简单的文件转向，直接引用了另一个Makefile文件（build/core/main.mk）。具体如下所示：

```
/*Makefile*/
### DO NOT EDIT THIS FILE ###
include build/core/main.mk
### DO NOT EDIT THIS FILE ###
```

这个被引用的main.mk文件有上千行代码，对于Makefile文档来说是比较大的。另外，它又进一步引用了很多其他脚本文件，使得整个文件的内部结构看起来杂乱无章。即便有不少注释，仍让很多初学者“望而却步”。

基于这个原因，如果一开始我们就照着Makefile文件一行行解释，很可能会“事倍功半”。建议大家牢记Makefile依赖树的概念，以树根节点作为切入点寻求突围。当然，Android系统的依赖树可不像SimpleMakefile例子那样一目了然。如何找出它的根节点，并以此为基础逐步构建出一棵完整的依赖树还是需要花点工夫的。这要求我们对Make的工作原理有一定程度的理解。所需知识点总结如下：

（1）需要强调的是，编译系统中往往有不止一棵依赖树存在。比如我们在Android系统下使用“make”命令和“make sdk”的编译结果会迥然不同，这是因为它们分别执行了两棵不同的依赖树。

在没有显式指定编译目标的情况下（使用不带任何参数的“make”命令来执行编译），那么第一个符合要求的目标会被Make作为默认的依赖树根节点。这条规则也同样提醒我们在书写Makefile时一定要注意各Target的排放顺序。如果不慎将clean等目标放在最开始的位置，很可能会导致异常情况。

（2）原则上Make程序会对makefile中的内容按照顺序进行逐条解析。一个典型的解析过程分为三大步骤，即：

- 变量赋值、环境检测等初始化操作；
- 按照规则生成所有依赖树；
- 根据用户选择的依赖树，从叶到根逐步生成目标文件。

掌握了上面Makefile的基本规则后，对照main.mk就可以很快找出，“make”命令对应的依赖树的根节点是droid。它是这样定义的：

```
/*build/core/Main.mk*/
# This is the default target.  It must be the first declared targ
.PHONY: droid
DEFAULT_GOAL := droid
$(DEFAULT_GOAL):
```

从注释中也可以佐证我们的猜测，即droid就是“default target”，而且“It must be the first declared target”——只不过这里的droid还是一个空的“规则”，相当于是我们预先占了个位置以保证它是第一个出现的目标。

那么，droid的真正“规则”是在哪里定义的呢？

仔细观察的话，会发现main.mk后续内容还有多个地方对droid进行了定义。而且根据TARGET_BUILD_APPS值的不同，出现了两个分支。如下源码所示：

```
ifneq ($(TARGET_BUILD_APPS),) ##只编译APP，而不是整个系统
  …
.PHONY: apps_only
apps_only: $(unbundled_build_modules)
droid: apps_only ##这种情况下droid只依赖于apps_only

else #非TARGET_BUILD_APPS的情况，此时需要编译整个系统
  $(call dist-for-goals, droidcore, \
    $(INTERNAL_UPDATE_PACKAGE_TARGET) \
    $(INTERNAL_OTA_PACKAGE_TARGET) \
    $(SYMBOLS_ZIP) \
    $(INSTALLED_FILES_FILE) \
    $(INSTALLED_BUILD_PROP_TARGET) \
    $(BUILT_TARGET_FILES_PACKAGE) \
    $(INSTALLED_ANDROID_INFO_TXT_TARGET) \
    $(INSTALLED_RAMDISK_TARGET) \
    $(INSTALLED_FACTORY_RAMDISK_TARGET) \
$(INSTALLED_FACTORY_BUNDLE_TARGET) \
)
  …
droid: droidcore  dist_files##当编译整个系统时，droid的依赖关系
endif # TARGET_BUILD_APPS
```

从上面这段代码可以看出，我们既可以编译整个系统，也可以选择只编译App。第二种情况使用的场景比较少——此时droid只依赖于apps_only，而后者又进一步取决于$(unbundled_build_modules)变量，有兴趣的读者可以自行分析。

编译整个系统是我们的首选，即上述代码中“else”部分的内容。很显然，这时候droid有两个PREREQUISITES：droidcore和dist_files，如图3-3所示。

我们将在后续几个小节具体分析droidcore和dist-files。

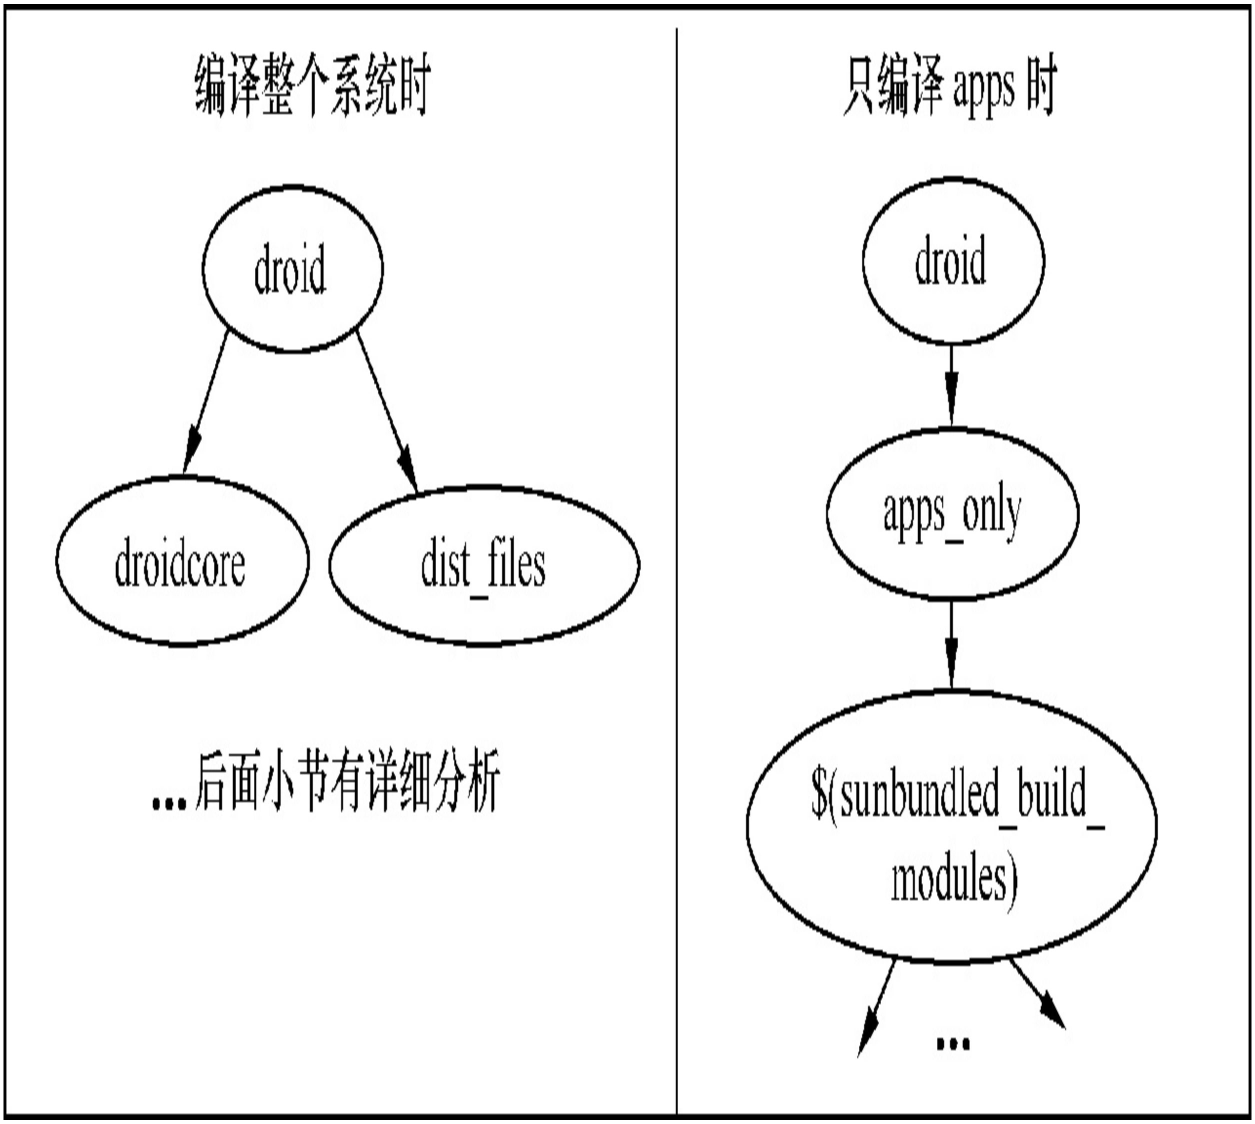

▲图3-3　droid的依赖树

3.2.4　main.mk解析

讲解droidcore和dist_files之前，我们先完整分析下main.mk脚本文件的架构。除了构建droid等依赖树外，main.mk有一大半的内容是为

了完成以下几点。

- 对编译环境的检测

比如Java版本是否符合要求，当前机器上的make环境必须高于特定版本等。如果这些检查没有通过，一般情况下系统会终止编译。

- 进行一些必要的前期处理

比如说整个项目工程是否需要先进行清理工作，部分工具的安装等。

- 引用其他Makefile文件

这点在整个main.mk中处处可见，如引用config.mk，cleanbuild.mk等。

- 设置全局变量

这些全局变量决定了编译的具体实现过程。

- 各种函数的实现

Android编译系统中定义了不少函数，它们提供了各种问题的统一解决方案。比如print-vars函数用于打印一串变量列表，my-dir可以知道当前所处的路径等。这些函数对我们自己编写Makefile文件也有一定的指导意义。

根据前一章节内容的讲解，为Android系统添加一款定制设备需要涉及如下几个脚本文件。

```
vendorsetup.sh
AndroidProducts.mk
BoardConfig.mk
Android.mk
```

其中vendorsetup.sh是在envsetup.sh中被调用的，其他几个Makefile的调用时序图及调用关系如图3-4所示。

从图3-4中可以清楚地看到，Android.mk是最后才被main.mk调用的。换句话说，前面的步骤都是在决定选择“什么产品”以及“产品的属性”，而最后才是考虑该产品的“零件”组成——每个“零件”都由一个Android.mk描述。比如我们生产一台电视机，先是通过读取配置来获知电视的具体属性（多大尺寸、是否LCD、是否壁挂等），最后才是考虑它的具体“零件”组成（某品牌的屏幕、螺丝、支架等）。

整个编译过程中起主导作用的是main.mk，我们从它的文件名就可以看出来。和main.mk同样重要的还有config.mk，这个专职“配置”的脚本可以说是“产品的设计师”——除了BoardConfig.mk和AndroidProducts.mk这两个“定制设备”必备的文件外，其他诸如javac.mk（用于选取合适的java编译器）、envsetup.mk（负责环境变量的定义）等Makefile也都属于其管辖范围。另外，BUILD系列变量（即BUILD_HOST_STATIC_LIBRARY、BUILD_STATIC_LIBRARY）也是在这里赋值的。

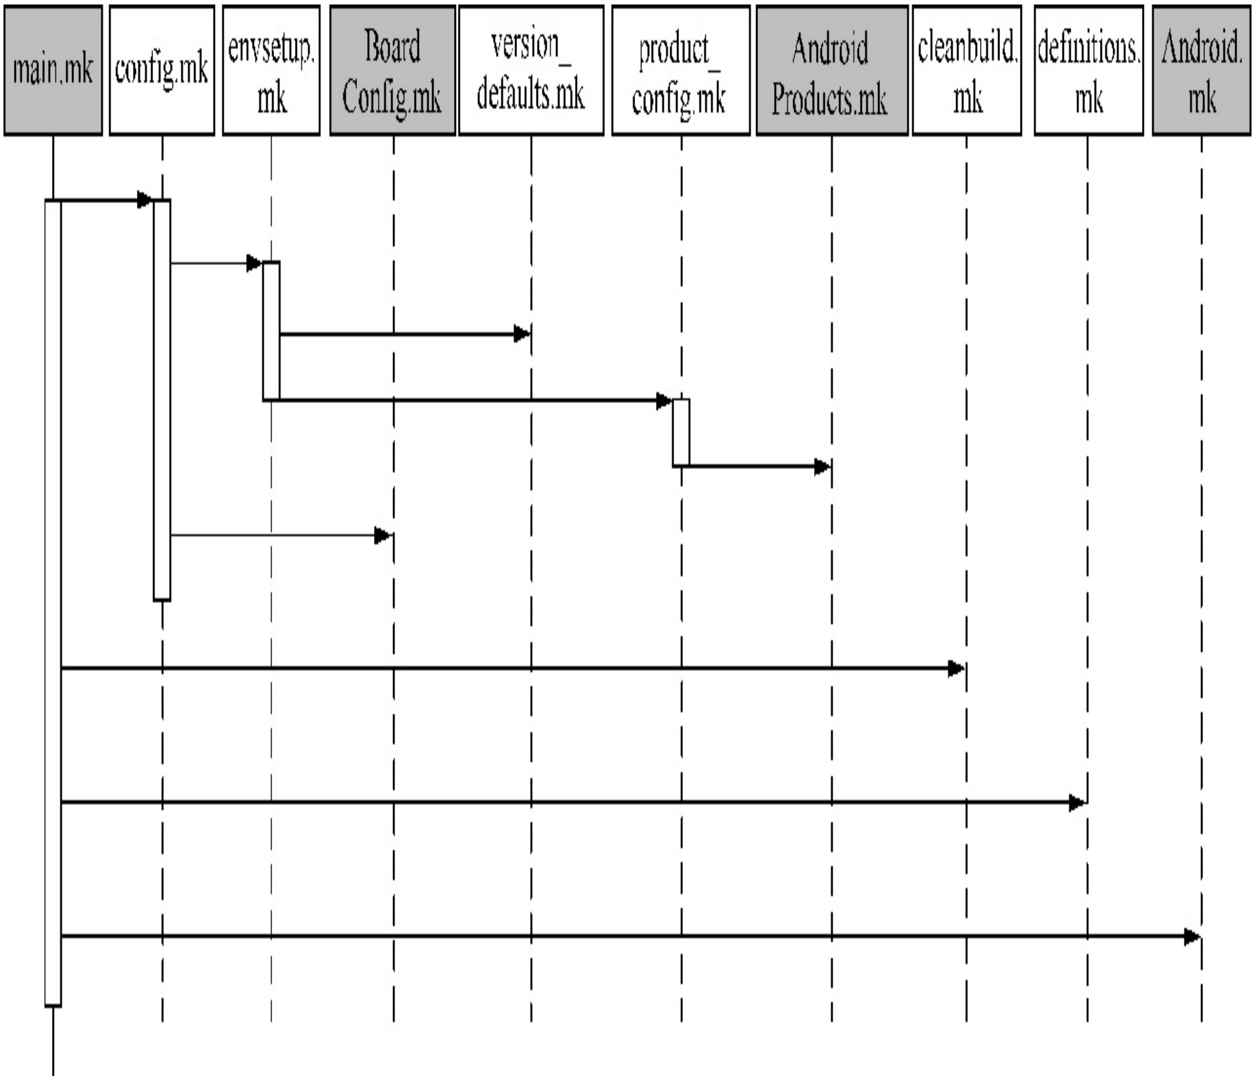

▲图3-4　各主要Makefile的调用时序图

表3-2所示是对Android编译系统中涉及的主要Makefile文件的统一解释，可供有需要的读者参考。

表3-2　主要Makefile文件释义

Name	Description
main.mk	整个编译系统的主导文件

config.mk	产品配置的主导文件
base_rules.mk	编译系统需要遵循的基础规则定义。其中最重要的 将各 Android.mk中的LOCAL_MODULE添加到全局依赖 整个系统的编译中。 另两个起到关键作用的变量是LOCAL_BUILT_MO LOCAL_INSTALLED_MODULE （添加到ALL_MODULES的是my_register_name， 赋值如下： LOCAL_BUILT_MODULE=out/target/product/gener intermediates/javalib.jar LOCAL_INSTALLED_MODULE=out/target/product
build_id.mk	版本id号的定义
cleanbuild.mk	clean操作的定义
clear_vars.mk	清空以LOCAL开头的相关系统变量，下一小节会
definitions.mk	提供了大量实用函数的定义
envsetup.mk	配置编译时的环境变量，注意要与envsetup.sh区分
executable.mk	负责BUILD_EXECUTABLE的具体实现
java.mk	负责与java语言相关的编译实现，是java_library.m 参见表后面的示意图

host_executable.mk	负责BUILD_HOST_EXECUTABLE的具体实现
host_static_library.mk	负责BUILD_HOST_STATIC_LIBRARY的具体实现 另外，其他类型的BUILD_XX变量也都有其对应的
product_config.mk	产品级别的配置，属于config的一部分
version_defaults.mk	负责生成版本信息，默认格式为： BUILD_NUMBER := eng.$(USER).$(shell date +%Y

编译生成Java库的典型依赖关系如图3-5所示。

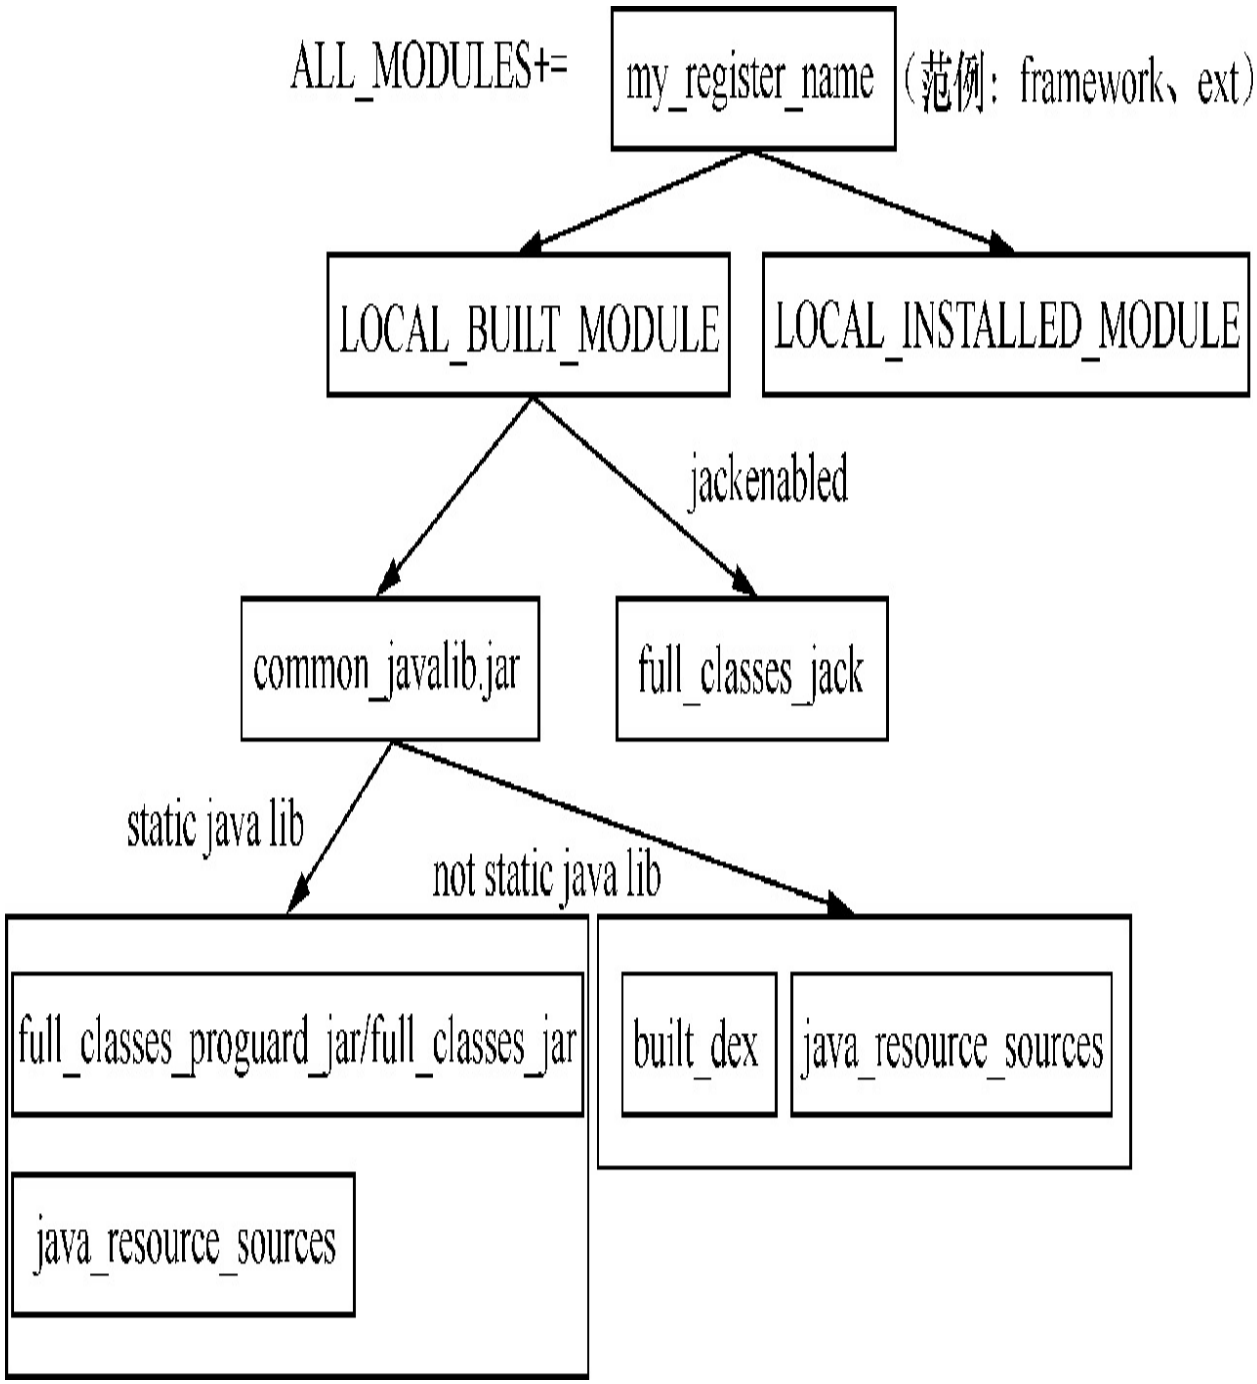

▲图3-5　典型依赖关系

Java.mk中定义了多个中间和最终产物的生成规则，包括：

```
LOCAL_INTERMEDIATE_TARGETS += \
    $(full_classes_compiled_jar) \
    $(full_classes_jarjar_jar) \
```

```
$(full_classes_emma_jar) \
$(full_classes_jar) \
$(full_classes_proguard_jar) \
$(built_dex_intermediate) \
$(full_classes_jack) \
$(noshrob_classes_jack) \
$(built_dex) \
$(full_classes_stubs_jar)
```

上述这些变量的具体描述如表3-3所示。

表3-3　具体的描述

变　量	对应的具体产物	生 成 规
full_classes_compiled_jar	classes-no-debug-var.jar或者classes-full-debug.jar	$(**full_classes_compiled_ja** $(java_sources) \ $(java_resource_ $(full_java_lib_d $(jar_manifest_fi $(layers_file) \ $(RenderScript_f $(proto_java_sou $(LOCAL_MOD \ $(LOCAL_ADDITIONAL_ $(transform-java-to-c
full_classes_jarjar_jar	classes-jarjar.jar	当存在JarJar规则时： $(**full_classes_jarjar_jar**): $(**full_classes_compiled_ja** (LOCAL_JARJAR_RULES @echo JarJar: $@ $(hide) java -jar $(JA (PRIVATE_JARJAR_RUL

full_classes_emma_jar	lib/ classes-jarjar.jar	$(**full_classes_emma_jar**): $(**full_classes_jarjar_jar**) $(transform-classes.ja
full_classes_jar	classes.jar	$(**full_classes_jar**): $(**full_** | $(ACP) @echo Copying: $@ $(hide) $(ACP) -fp $<
full_classes_proguard_jar	proguard.classes.jar或者 noproguard.classes.jar	$(**full_classes_proguard_j** $(**full_classes_jar**) $(extra_ $(my_support_library_sdk_ $(proguard_flag_files) | $(A $(PROGUARD) $(call transform-jar-to
built_dex_intermediate	no-local（或者with-local）/ classes.dex	$(**built_dex_intermediate**) $(**full_classes_proguard_j** $(transform-classes.ja
full_classes_jack	classes.jack	$(**full_classes_jack**): $(**jac** @echo Building with $(java-to-jack)
built_dex	classes.dex	$(**built_dex**): $(**built_dex_** $(ACP) @echo Copying: $@ $(hide) mkdir -p $(dir $(hide) rm -f $(dir $@ $(hide) $(ACP) -fp $($(dir $@)

		ifneq ($(GENERATE_DE $(install-dex-debug) endif

请大家注意观察表3-3中的黑色加粗字体，不难发现java.mk中的这几个变量之间存在着相互依赖关系，可以说是“环环相扣”：

built_dex-> built_dex_intermediate -> full_classes_proguard_jar -> full_classes_jar->full_classes_emma_jar->full_classes_jarjar_jar->full_classes_compiled_jar->java_sources+java_resource_sources+ full_java_lib_deps+jar_manifest_file…

当然，如果开启了Jack编译，那么依赖关系会有所不同。Jack与传统编译方式一个重要的区别就是，它会直接生成最终的dex文件——不过在Static Java Library的情况下它还需要生成.jack文件。

3.2.5　droidcore节点

在编译整个Android系统（而不是只有App）的情况下，droid依赖于droidcore和dist_files。这一小节先来分析下droidcore节点的生成过程。其规则定义如下：

```
# Build files and then package it into the rom formats
.PHONY: droidcore
droidcore: files \
	systemimage \
	$(INSTALLED_BOOTIMAGE_TARGET) \
	$(INSTALLED_RECOVERYIMAGE_TARGET) \
	$(INSTALLED_USERDATAIMAGE_TARGET) \
	$(INSTALLED_CACHEIMAGE_TARGET) \
	$(INSTALLED_VENDORIMAGE_TARGET) \
	$(INSTALLED_FILES_FILE)
```

可以看到，droidcore依赖于如表3-4所示的几个Prerequisites。

表3-4　droidcore的prerequisites

Prerequisite	**Description**

files	代表其所依赖的“先决条件”的集合，没有实际意义
systemimage	将生成system.img
$(INSTALLED_BOOTIMAGE_TARGET)	将生成boot.img
$(INSTALLED_RECOVERYIMAGE_TARGET)	将生成recovery.img
$(INSTALLED_USERDATAIMAGE_TARGET)	将生成userdata.img
$(INSTALLED_CACHEIMAGE_TARGET)	将生成cache.img
$(INSTALLED_VENDORIMAGE_TARGET)	将生成vendor.img
$(INSTALLED_FILES_FILE)	将生成installed-files.txt，用于记录当前系统中预安装的程序、库等模块

这几个“先决条件”的产生原理都类似，因而我们只挑选前几个来做重点分析。

1．files

定义如下：

```
# All the droid stuff, in directories
.PHONY: files
files: prebuilt \
        $(modules_to_install) \
        $(INSTALLED_ANDROID_INFO_TXT_TARGET)
```

（1）prebuilt。“prebuilt”也是一个伪目标，它依赖于$(ALL_PREBUILT)变量。ALL_PREBUILT机制只用于早期的版本，目前已经被废弃，建议大家使用它的替代品PRODUCT_COPY_FILES。

（2）modules_to_install。如其名称所示，这个变量描述了系统需要安装的模块。

```
modules_to_install := $(sort \
    $(ALL_DEFAULT_INSTALLED_MODULES) \
    $(product_FILES) \
    $(foreach tag,$(tags_to_install),$($(tag)_MODULES)) \
    $(call get-tagged-modules, shell_$(TARGET_SHELL)) \
    $(CUSTOM_MODULES) \
  )
```

由此可见，这些模块被分为五部分，最核心的是下面两种。

- product_FILES

编译该产品涉及的相关文件。与product_FILES有直接联系的是product_MODULES，后者则是基于PRODUCT_PACKAGES的处理结果。简而言之，product_FILES是各modules（比如framework，Browser）需要安装文件的列表。

- tags_to_install所对应的Modules

在Android编译机制中，模块是可以指定编译标志的，如user、debug、eng、tests。通过给各模块打上相应标志，可以在编译时有选

择地避开某些无用的功能部件。

比如开发人员在当次编译时特别指定了eng标志，那么所有与此无关的模块都将被排除在最终生成的系统之外。具体而言，$(tag)_MODULES变量赋值后得到的是eng_MODULES，后者又由函数get-tagged-modules来进一步填充：

```
eng_MODULES := $(sort \
        $(call get-tagged-modules,eng) \
        $(call module-installed-files, $(PRODUCTS.$(INTERNAL_PRODUCT).PRODUCT_PACKAGES_ENG)) \
    )
debug_MODULES := $(sort \
        $(call get-tagged-modules,debug) \
        $(call module-installed-files, $(PRODUCTS.$(INTERNAL_PRODUCT).PRODUCT_PACKAGES_DEBUG)) \
    )
```

接下来我们分析get-tagged-modules的函数实现：

```
# Given an accept and reject list, find the matching
# set of targets.  If a target has multiple tags and
# any of them are rejected, the target is rejected.
# Reject overrides accept.
# $(1): list of tags to accept
# $(2): list of tags to reject
#TODO(dbort): do $(if $(strip $(1)),$(1),$(ALL_MODULE_TAGS))
#TODO(jbq): as of 20100106 nobody uses the second parameter
define get-tagged-modules
$(filter-out \
    $(call modules-for-tag-list,$(2)), \
        $(call modules-for-tag-list,$(1)))
endef
```

可以看到，这个函数并不只单纯寻找符合tag要求的候选者，而是综合考虑了“可接受”和“拒绝”两种情况。简单来说，当一个目标既有“可接受”标签，又有“拒绝”标签时，它仍然会被淘汰。

“可接受”对象的查找则由modules-for-tag-list来实现。其定义如下：

```
# Given a list of tags, return the targets that specify
# any of those tags.
# $(1): tag list
define modules-for-tag-list
$(sort $(foreach tag,$(1),$(ALL_MODULE_TAGS.$(tag))))
endef
```

需要注意的是，main.mk在后续编译过程中还会对modules_to_install进行若干次过滤，目的就是去掉不符合条件和重复无效的部分。

（3）$(INSTALLED_ANDROID_INFO_TXT_TARGET)的生成流程和前两个变量相似，读者可以作为练习自行分析。

2. systemimage

systemimage的规则定义在build/core/Makefile中：

```
$(INSTALLED_SYSTEMIMAGE): $(BUILT_SYSTEMIMAGE) $(RECOVERY_FROM_BOOT_PATCH) | $(ACP)
	@echo "Install system fs image: $@"
	$(copy-file-to-target)
	$(hide) $(call assert-max-image-size,$@ $(RECOVERY_FROM_BOOT_PATCH),$(BOARD_SYSTEMIMAGE_PARTITION_SIZE),yaffs)

systemimage: $(INSTALLED_SYSTEMIMAGE)
```

不难看出，这个规则中最重要的Prerequisite是$(BUILT_SYSTEMIMAGE)，它和systemimage一样也是在同一个Makefile文件中定义的。最终system.img文件就是通过它来生成的，采用的COMMAND是：

```
$(call build-systemimage-target,$@)
```

参数“$@”是Makefile定义的一个自动化变量，代表所有targets的集合。

这样就可以成功编译出system.img了。

总的来说，droidcore负责生成系统的所有可运行程序包，包括system.img，boot.img，recovery.img等。

3.2.6 dist_files

根节点droid还有另一个依赖，即dist_files。它在整个编译项目中只出现了一次，如：

```
# dist_files only for putting your library into the dist directory with a full build.
.PHONY: dist_files
```

按照Android的设计，当这个目标节点起作用时，会在out目录下产生专门的dist文件夹，用于存储多种分发包。而通常情况下，它既不做任何工作，也不会对我们理解整个编译系统产生影响，因此读者可以选择跳过。

3.2.7 Android.mk的编写规则

一棵大树的繁茂和枝叶的多寡是息息相关的。一方面，只有茁壮的枝干才能提供足够的养分来供给它的众多细枝末叶；另一方面，树叶的光合作用同样可以滋养整棵大树，从而使其呈现出欣欣向荣之态。

我们曾不止一次地提到过，Android系统是由非常多的子项目组成的。一款优秀的开放式操作系统，除了要能在原生态系统中预先兼容诸多第三方模块外，还应该具有良好的后期动态扩展性。比如一家互联网厂商希望将其自行研发的某个APK应用程序集成进Android系统中；或者某家主打“音乐概念”的手机公司打算把某个音频解析库编译进系统版本中。

那么，良好的动态扩展性对这两家公司而言就意味着不需要花太多时间去关心整个Android编译体系的运作原理，就能完成以上两个需求——这就像驾驶员适当地了解发动机内部结构能让他们在道路上更得心应手，但我们不能因此就强制要求大家必须理解发动机原理才能开车。

这就是Android.mk的一大意义所在。

Android.mk在整个源码工程中随处可见，保守估计其总体数量在一千个以上。

那么如此之多的文件，又是如何整合进庞大的编译系统而保证不会出错的呢？下面的代码是将源码工程中所有Android.mk添加进编译系统的处理过程（在main.mk中定义）：

```
ifneq ($(ONE_SHOT_MAKEFILE),)
include $(ONE_SHOT_MAKEFILE)
CUSTOM_MODULES := $(sort $(call get-tagged-modules,$(ALL_MODULE_TAGS)))
FULL_BUILD :=
# Stub out the notice targets, which probably aren't defined
# when using ONE_SHOT_MAKEFILE.
NOTICE-HOST-%: ;
NOTICE-TARGET-%: ;

else # ONE_SHOT_MAKEFILE

#
# Include all of the makefiles in the system
#
# Can't use first-makefiles-under here because
# --mindepth=2 makes the prunes not work.
subdir_makefiles := \
    $(shell build/tools/findleaves.py --prune=out --prune=.repo --prune=.git $(subdirs) Android.mk)

include $(subdir_makefiles)

endif # ONE_SHOT_MAKEFILE
```

变量ONE_SHOT_MAKEFILE和编译选项有关。如果选择了编译整个工程项目，那么这个变量就是空的；否则如果使用了诸如"make mm"之类的部分编译命令时，那么在mm的实现里会对ONE_SHOT_MAKEFILE进行必要的赋值。

在编译整个工程的情况下，系统所找到的所有Android.mk将会先存入subdir_makefiles变量中，随后一次性include进整个编译文件中。

接下来，我们选取adb项目作为例子详细解释Android.mk的编写规则及一些注意事项。之所以挑选adb程序，是因为本书的工具篇中还会对其内部原理进行剖析——理解一个程序很重要的前提就是读懂它的Makefile，这将为我们后期的学习打下一定的基础。

Adb的源码路径在system/core/adb中，我们只摘抄其Android.mk中的核心实现。具体如下所示：

```
LOCAL_PATH:= $(call my-dir) /*LOCAL_PATH的位置先于CLEAR_VARS*/
include $(CLEAR_VARS)
/*CLEAR_VARS的定义在/build/core/clear_vars.mk中，它清除了上百个除LOCAL
```

```
USB_SRCS :=
EXTRA_SRCS :=
/*adb内部定义的两个变量，将在不同的操作系统环境下赋予不同的文件值。因为不同的
ifeq ($(HOST_OS),linux) /*Linux环境下*/
  USB_SRCS := usb_linux.c
  EXTRA_SRCS := get_my_path_linux.c
  LOCAL_LDLIBS += -lrt -ldl -lpthread
  LOCAL_CFLAGS += -DWORKAROUND_BUG6558362
endif
…/*省略其他操作系统下的类似处理*/
LOCAL_SRC_FILES := \
     adb.c \
     …
     $(EXTRA_SRCS) \
     $(USB_SRCS) \
     utils.c \
     usb_vendors.c
/*LOCAL_SRC_FILES是一个很重要的变量，它定义了本模块编译所涉及的所有源文件。
  的两个变量，即USB_SRCS和EXTRA_SRCS也在这里被加入到了编译列表中*/
…
ifneq ($(USE_SYSDEPS_WIN32),)
  LOCAL_SRC_FILES += sysdeps_win32.c/*根据实际情况来扩展LOCAL_SRC_FI
else
  LOCAL_SRC_FILES += fdevent.c
endif

LOCAL_CFLAGS += -O2 -g -DADB_HOST=1  -Wall  -Wno-unused-parameter
LOCAL_CFLAGS += -D_XOPEN_SOURCE -D_GNU_SOURCE
/*上面两行用于添加编译标志，这在编译过程中会起作用*/
LOCAL_MODULE := adb/*所要生成的模块的名称*/
…
LOCAL_STATIC_LIBRARIES := libzipfile libunz libcrypto_static $(EX
…
include $(BUILD_HOST_EXECUTABLE)
/*这个语句是整个Android.mk的重点。BUILD_HOST_EXECUTABLE表示我们希望生成
…
/*到目前为止的语句仅定义了adb host工具的生成过程，这个程序将运行于开发环境所

/*以下内容是adbd的编译配置，这个程序运行于设备端*/
include $(CLEAR_VARS)/*第二个模块编译的开始标志*/
LOCAL_SRC_FILES := \
     adb.c \
     …
     Utils.c
/*从LOCAL_SRC_FILES变量可以发现，adb daemon和adb host所涉及的文件是有重
…/*省略和第一个模块中类似的语句*/
LOCAL_MODULE := adbd/*模块名称*/
…
```

```
LOCAL_STATIC_LIBRARIES := libcutils libc libmincrypt
include $(BUILD_EXECUTABLE)/*到这里为止，第二个模块的编译配置结束，最终生
```

通过以上对Android.mk文件的分析，我们了解到ADB工具分为两部分，即ADB Host（Client和Server）和ADB Daemon。前者将和开发环境运行于同一机器平台中，后者则面向设备本身。

上述脚本代码中用到的所有Android编译系统提供的函数与变量，我们都特别标注了出来。从中可以看到，通过Android.mk添加一个编译模块到系统中的顺序如下：

- LOCAL_PATH;
- CLEAR_VARS;
- LOCAL_SRC_FILES;
- LOCAL_CFLAGS（可选）；
- LOCAL_MODULE;
- LOCAL_STATIC_LIBRARIES（可选）；
- BUILD_HOST_EXECUTABLE/BUILD_EXECUTABLE等。

最后，总结下Android.mk的几个使用要点。

（1）我们可以把Android.mk的处理步骤与食品制作过程做个类比。

- 准备食材。包括LOCAL_SRC_FILES，LOCAL_MODULE，LOCAL_STATIC_LIBRARIES的收集。虽然每道菜都会有不同的原料需求，但细心的厨师（Android编译系统）事先都考虑到了。他做好了合理的分类（调味类、肉类、蔬菜类等），并提供了完整的清单。我们所要做的工作就是按照这些清单逐项采购。
- 烹饪菜肴。准备好食材以后，就可以开始佳肴的烹饪了。得益于Android编译系统的用心，这个过程比我们想象中的简单很多。因为同一道菜的烧制工序是一样的，所以Google事先就把这些步骤集合起来，并做好了各种模板，如BUILD_STATIC_LIBRARY，BUILD_SHARED_LIBRARY，BUILD_EXECUTABLE等。一旦顾客点了哪道菜，我们只要调用这些固有模板就可以轻松完成整个烹饪过程，非常方便。

（2）每个Android.mk都允许同时煮几道菜，每个清单将以下面的语句开始：

```
include $(CLEAR_VARS)
```

并以如下语句结束：

```
include $(BUILD_XXX)
```

注：BUILD_XXX代表上面所提及的各个编译模板

（3）表3-5所示是在编写Android.mk时所涉及的常用重要变量，供读者参考。

表3-5　Android.mk中常用的重要变量解析

变　量　名	说　　明
LOCAL_PATH	用于确定源码所在的目录，最好把它放在CLEAR_VARS变量引用的前面。因为它不会被清除，每个Android.mk只需要定义一次即可
CLEAR_VARS	它清空了很多以“LOCAL_”开头的变量（LOCAL_PATH除外）。由于所有的Makefile都是在一个编译环境中执行的，因此变量的定义理论上都是全局的，在每个模块编译开始前进行清理工作是必要的
LOCAL_MODULE	模块名，需保证在整个编译系统中是唯一存在的，而且中间不可以有空格
LOCAL_MODULE_PATH	模块的输出路径

LOCAL_SRC_FILES	模块编译过程所涉及的源文件。如果是Java程序，可以考虑调用all-subdir-java-files来一次性添加目录（包括子目录）下所有的Java文件因为有LOCAL_PATH，这里只需要给出文件名（相对路径）即可；而且编译系统有比较强的推导功能，可以自动计算依赖关系
LOCAL_CC	用于指定C编译器
LOCAL_CXX	用于指定C++编译器
LOCAL_CPP_EXTENSION	用于指定特殊的C++文件后缀名
LOCAL_CFLAGS	C语言编译时的额外选项
LOCAL_CXXFLAGS	C++语言编译时的额外选项
LOCAL_C_INCLUDES	编译C和C++程序所需的额外头文件
LOCAL_STATIC_LIBRARIES	编译所需的静态库列表
LOCAL_SHARED_LIBRARIES	编译所需的共享库列表
LOCAL_JAVA_LIBRARIES	编译时所需的JAVA类库

LOCAL_LDLIBS	编译时所需的链接选项
LOCAL_COPY_HEADERS	安装应用程序时所需复制的头文件列表，需要和LOCAL_COPY_HEADERS_TO变量配合使用
LOCAL_COPY_HEADERS_TO	上述头文件列表的复制目的地
BUILD_HOST_STATIC_LIBRARY BUILD_HOST_SHARED_LIBRARY BUILD_STATIC_LIBRARY BUILD_RAW_STATIC_LIBRARY BUILD_SHARED_LIBRARY BUILD_EXECUTABLE BUILD_RAW_EXECUTABLE BUILD_HOST_EXECUTABLE BUILD_PACKAGE BUILD_HOST_PREBUILT BUILD_PREBUILT BUILD_MULTI_PREBUILT BUILD_JAVA_LIBRARY BUILD_STATIC_JAVA_LIBRARY BUILD_HOST_JAVA_LIBRARY BUILD_DROIDDOC BUILD_COPY_HEADERS BUILD_KEY_CHAR_MAP	各种形式的编译模板，如生成设备端或者Host端的静态、动态库文件（Java和C/C++等），可执行文件，文档等 需要大家特别注意的是BUILD_JAVA_LIBRARY和BUILD_STATIC_JAVA_LIBRARY之间的区别。后者生成的Java Library既不会被安装，也不会被放到Java的Classpath中。而BUILD_JAVA_LIBRARY得到的Java库是具有“共享”性质的，可以为多个程序所共用（会被复制到/system/framework中）

在本章的学习中，我们先从最基础的Makefile语法规则入手，导出了依赖树的概念；然后按照由上而下的顺序，逐步梳理出编译一个完整的Android版本所涉及的几个重要节点。

Android编译系统是非常庞大的，所包括的节点和文件数量远不止本章所描述的。不过，我们的目的是让读者掌握一种有效的分析编译系统的方法——相信只要按照本章的分析方法，再一步步地进行推导论断，整个Android编译体系就会“水落石出”了。

3.3 Jack Toolchain

从6.0版本开始，Android编译系统中一个比较大的变化是采用了全新的Java编译链，即Jack（Java Android Compiler Kit）。

Jack的主要任务是取代以前版本中的javac、ProGuard、jarjar、dx等诸多工具，以一种全新的方式来将Java源文件编译成Android的Dex字节码。它的优势在于可以加快编译速度，具有内建的shrinking、obfuscation、repackaging和multidex等功能，并且完全开源，如图3-6所示。

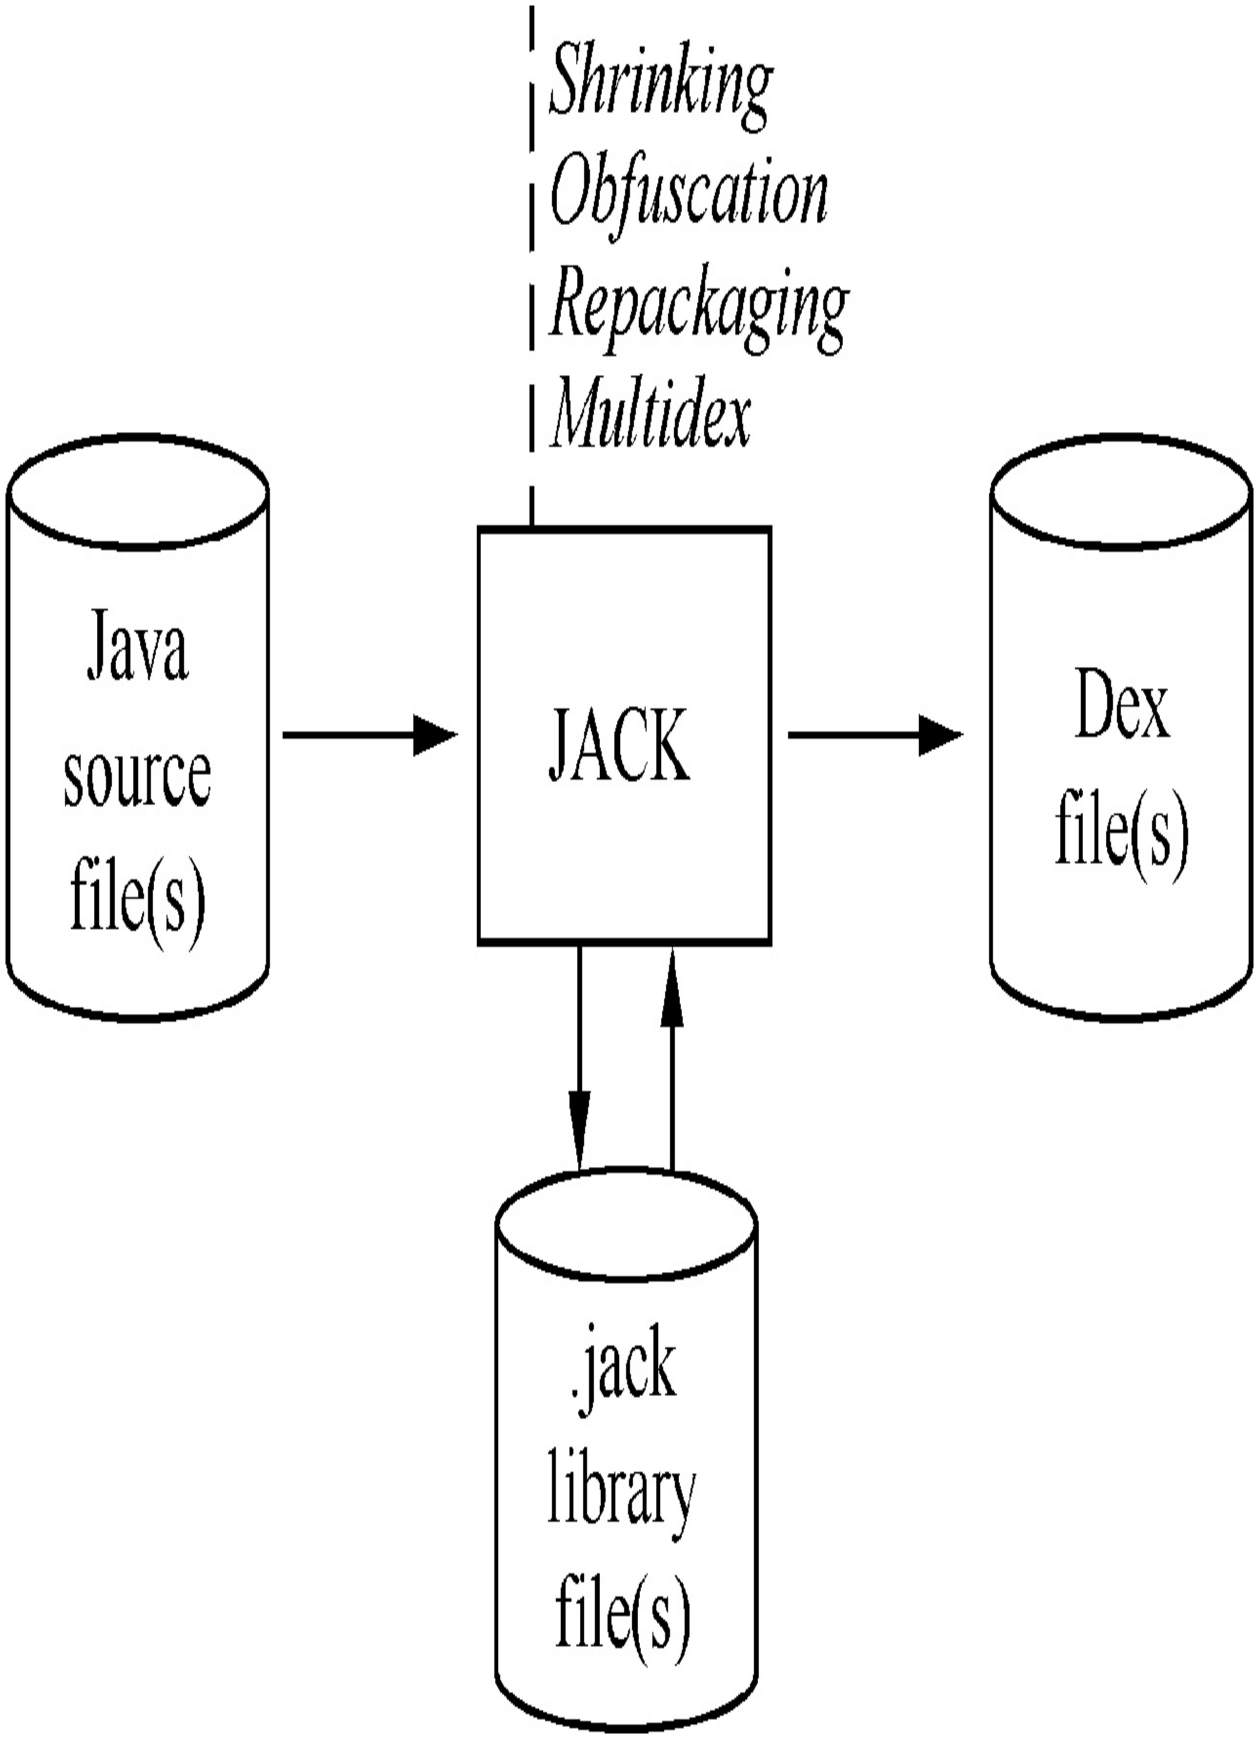
Shrinking
Obfuscation
Repackaging
Multidex
Java source file(s)
JACK
Dex file(s)
.jack library file(s)

▲图3-6 Jack简图
（引用自source.android.com）

Jack有自己的文件格式，这就不可避免地需要利用一个工具来将它与传统的.jar文件进行转换——即Jill（Jack Intermediate Library Linker）。如图3-7所示。

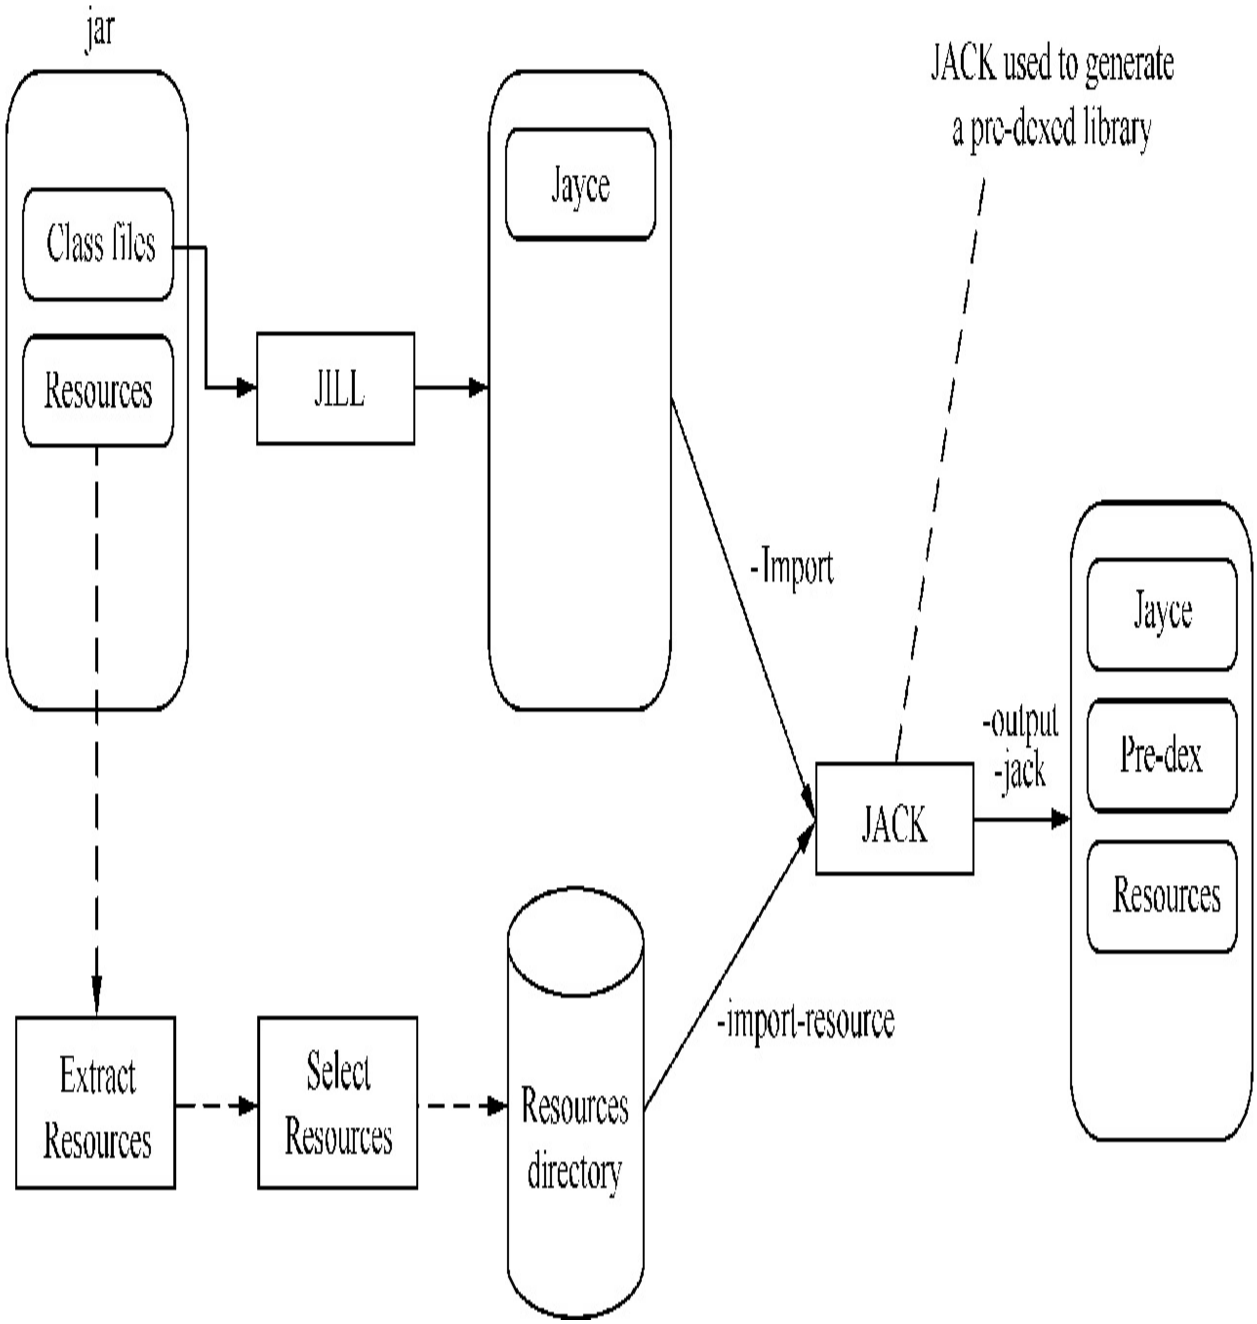

▲图3-7　Jill工作流程

（引用自source.android.com）

接下来我们重点讲解一下Jack在Android系统工程编译中的一些特点，以便大家可以学以致用。虽然Android官方承诺使用Jack的情况和以往的编译过程没有任何区别，但事实上总还是会出现因为Jack而导致编译失败的情况。譬如笔者就曾在M版本编译中遇到过如图3-8所示的问题。

```
Building with Jack: out/target/common/obj/JAVA_LIBRARIES/core-libart_intermediat
es/with-local/classes.dex

Launching background server java -Dfile.encoding=UTF-8 -Xms2560m -XX:+TieredComp
ilation -jar out/host/linux-x86/framework/jack-launcher.jar -cp out/host/linux-x
86/framework/jack.jar com.android.jack.server.JackSimpleServer
out/host/linux-x86/bin/jack: line 131: 24820 Killed                  $SERVER_PRG
 $SERVER_PORT_SERVICE $SERVER_PORT_ADMIN $SERVER_COUNT $SERVER_NB_COMPILE $SERVE
R_TIMEOUT >> $SERVER_LOG 2>&1
ERROR: Cannot launch Jack server
make: *** [out/target/common/obj/JAVA_LIBRARIES/core-libart_intermediates/with-l
ocal/classes.dex] Error 41
```

▲图3-8　编译时出现的问题

想要解决上述这个错误，首先就得理解Jack在编译系统中的工作过程。

Jack可以加快编译速度的一个重要原因是提供了一个能随时待命的Server，与以往的JRE JVM相比，这种方式显然可以节省启动和初始化的时间（这有点类似于Gradle的做法）。当然，如果一直没有新的编译任务到达，一定时长后，Jack Server也会自动关闭，以避免对系统资源的无端消耗。

Jack Server对应的配置文件是$HOME/.jack，其中包含了如表3-6所示的一些重要信息。

表3-6　重要的信息

Config Item	Description

SERVER=true	启用Jack Server功能，默认情况下是打开的
SERVER_PORT_SERVICE=8072	设置Server用于编译功能的端口号
SERVER_PORT_ADMIN=8073	设置Server用于管理功能的端口号
SERVER_COUNT=1	目前还未用到
SERVER_NB_COMPILE=4	并行编译的最大数量
SERVER_TIMEOUT=60	没有编译任务多长时间后Server应该关闭自身
	设置Server

SERVER_LOG=${SERVER_LOG:=$SERVER_DIR/jack-$SERVER_PORT_SERVICE.log}	运行时Log文件的存储路径
JACK_VM_COMMAND=${JACK_VM_COMMAND:=java}	在Host机上启动一个JVM实例的默认命令

根据前述问题的Log描述，我们不难发现编译失败的缘由是无法启动Jack Server。针对这种情况最可疑的原因就是Server所需的端口已经被Host机中其他程序占用了。所以解决办法就是在.jack配置文件中对Jack Server的端口号进行重新调整（建议选一个高位不常用的端口号，避免冲突）。

不过很遗憾，更改端口号对笔者的这个编译错误没有产生任何效果。再仔细观察一下编译过程输出的Log，可以发现另一个可疑点（开发人员也可以查看Jack Server输出的Log文件来定位问题），如图3-9所示。

▲图3-9　发现问题

可以看到Jack Server为虚拟机申请了高达2560m的堆内存，而笔者给编译Android系统的虚拟机环境只配置了2GB的内存，所以显然也会导致失败。解决的办法也很简单，就是扩大内存配额，然后重试——这次问题确实得到了解决，并成功完成了整个编译过程，参见图3-12。

我们再来观察一下Jack编译链下的中间文件。

其中BUILD_JAVA_LIBRARY的中间文件状态如图3-10所示。

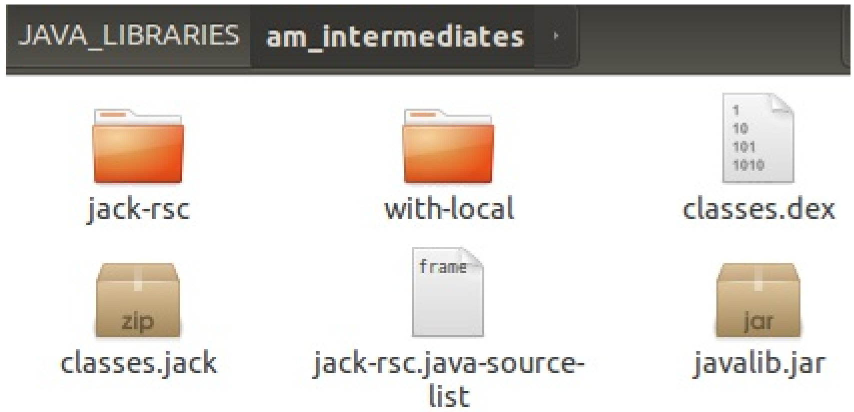

▲图3-10　Jack不再输出旧版本中的classes.jar等文件

而BUILD_STATIC_JAVA_LIBRARY的中间文件状态如图3-11所示。

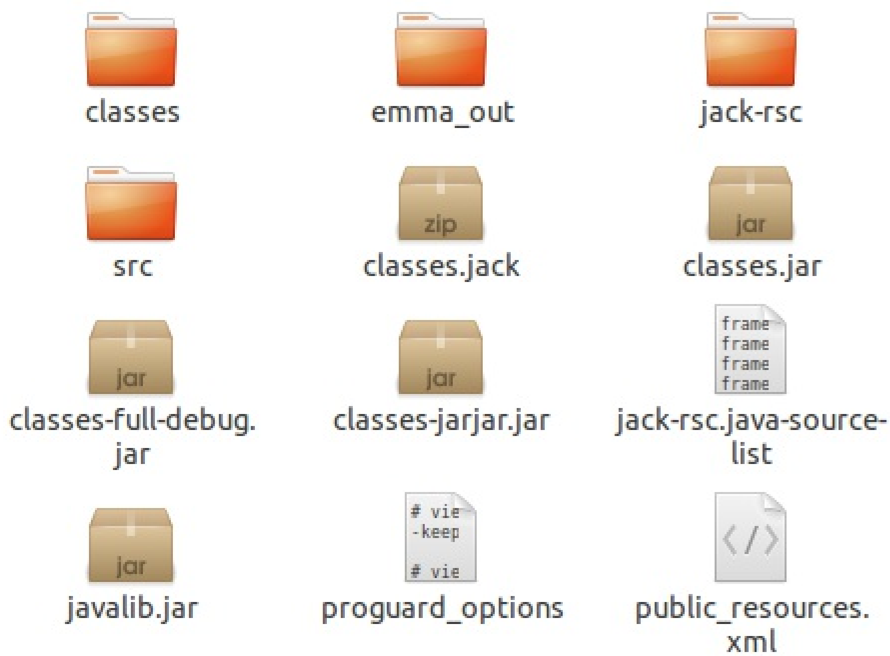

▲图3-11　中间文件夹状态

不难发现，Jack并不输出中间状态的jar文件，而是直接得到最终的dex产物——这也是它会导致一些分析工具失效的原因，例如著名的Jacoco代码覆盖率工具。

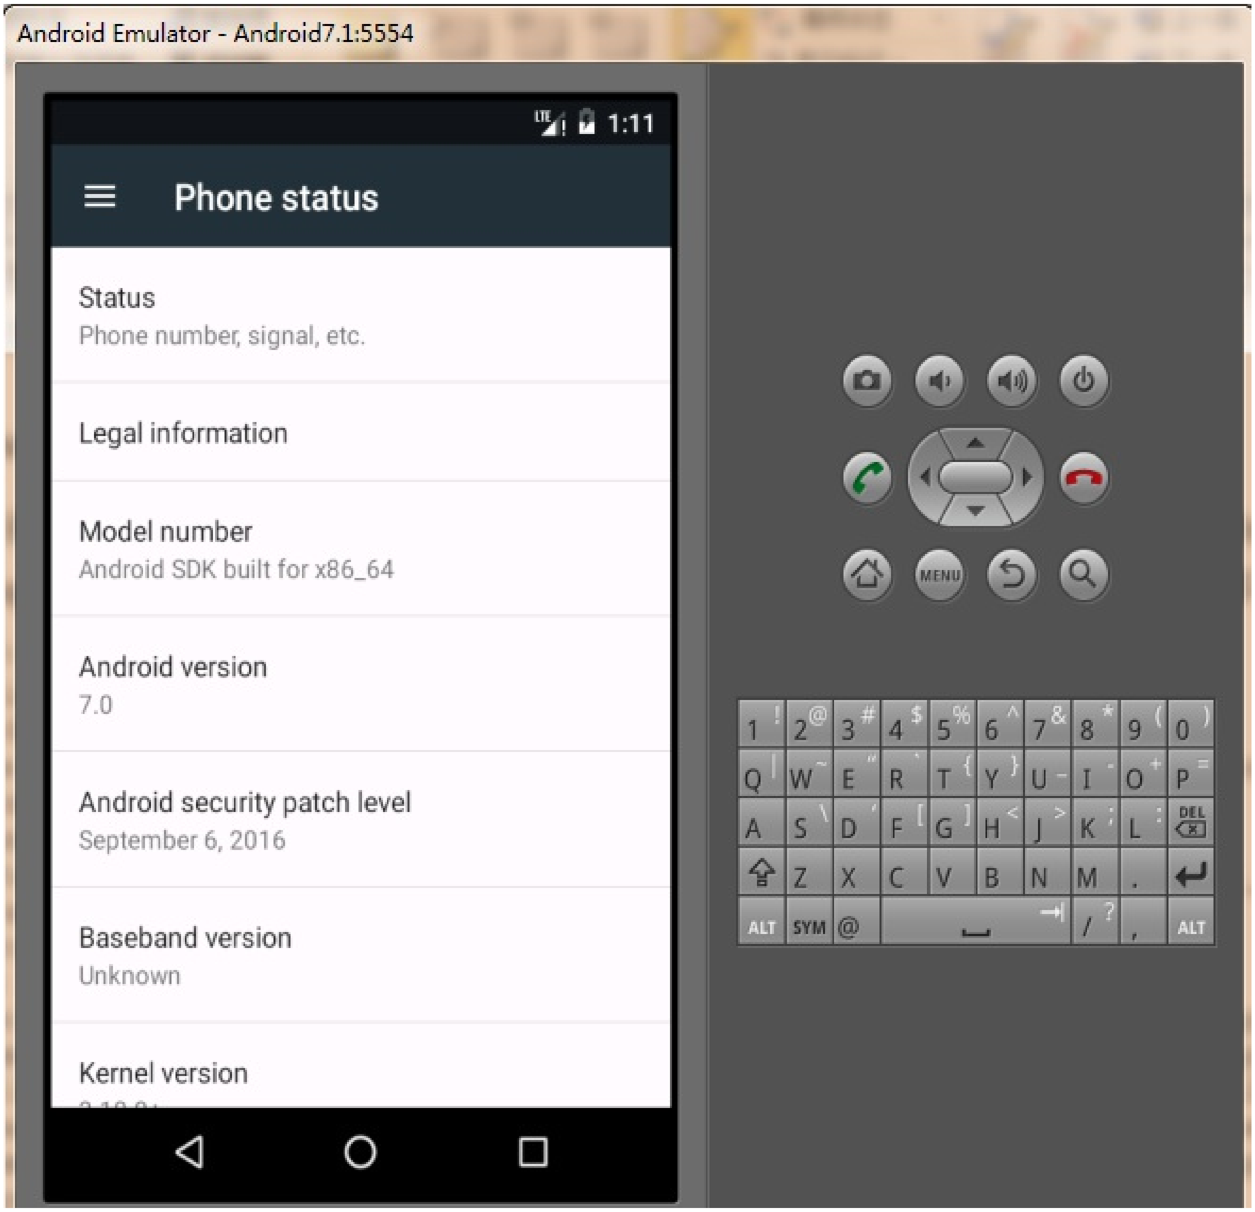

▲图3-12　Android 7.x模拟器运行效果

由于Jack是一项experimental的特性，或多或少都存在着一些bug，所以，大家在开发过程中，（包括应用程序和系统开发）如果遇到了确实是由于Jack所引发的问题，而且这个问题暂时还无法得到解决的话，那么可以选择不用Jack来进行编译（注意：并不是所有情况下都适用，比如存在其他依赖关系的时候）。具体做法是在Android.mk中添加如下语句：

```
LOCAL_JACK_ENABLED := disabled
```

3.4　SDK的编译过程

采用Android系统的设备厂商越来越多，不少公司便开始考虑如何编译出具有自己特色的扩展SDK。这种做法除了满足开发人员的需求外，还可以通过SDK来开放设备自身的优势，从而吸引更多的用户，提高市场竞争力。因而我们觉得很有必要分析一下SDK的生成过程，以便大家可以根据自己的需求来进行定制修改。

简单来说，SDK是Android系统提供给开发人员的一个“工具集”。它的典型文件结构大致如图3-13所示。

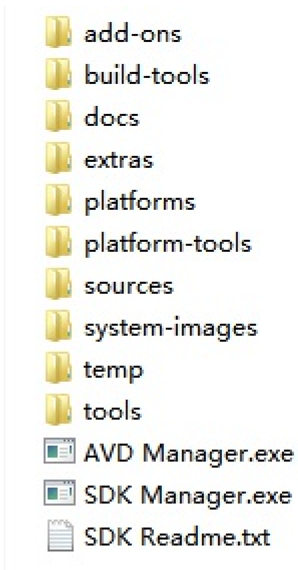

▲图3-13 Android SDK的典型文件结构

接下来我们按照编译Android SDK的步骤来进行讲解，并从编译脚本内部实现的角度来分析它的整个生成过程，同时也希望可以让读者借此更深入地理解Android编译系统。

3.4.1　envsetup.sh

相信通过前面章节的学习，大家都知道在编译Android系统之前，首先需要执行build目录下的envsetup.sh脚本。这个脚本中除了包含后续步骤所需的函数定义外，还会做很多准备工作。具体如下所示：

```
function hmm() {
```

```
cat <<EOF
Invoke ". build/envsetup.sh" from your shell to add the following
  - lunch: lunch <product_name>-<build_variant>
  - tapas: tapas [<App1> <App2> ...] [arm|x86|mips|armv5|arm64|x8
userdebug|user]
  - croot: Changes directory to the top of the tree.
  - m: Makes from the top of the tree.
  - mm: Builds all of the modules in the current directory, but n
  - mmm: Builds all of the modules in the supplied directories, b
  To limit the modules being built use the syntax: mmm dir/:targe
  - mma: Builds all of the modules in the current directory, and
  - mmma: Builds all of the modules in the supplied directories,
  - cgrep: Greps on all local C/C++ files.
  - ggrep: Greps on all local Gradle files.
  - jgrep: Greps on all local Java files.
  - resgrep: Greps on all local res/*.xml files.
  - mangrep: Greps on all local AndroidManifest.xml files.
  - sepgrep: Greps on all local sepolicy files.
  - sgrep: Greps on all local source files.
  - godir: Go to the directory containing a file.
  Environemnt options:
  - SANITIZE_HOST: Set to 'true' to use ASAN for all host modules
  ASAN_OPTIONS=detect_leaks=0 will be set by default until the
  build is leak-check clean.
  Look at the source to view more functions. The complete list is
  EOF
  T=$(gettop)
  local A
  A=""
  for i in 'cat $T/build/envsetup.sh | sed -n "/^[ \t]*function /
  A="$A $i"
  done
  echo $A
}
```

从hmm函数可以大概看出envsetup.sh所提供的功能，如表3-7所示。

表3-7　envsetup.sh脚本提供的主要函数释义

函　　数	描　　述
croot	回到树的根位置，即AOSP工程的根目录

m	从树根节点开始执行make
mm	make当前目录下的所有模块，但是不包括它们的依赖
mmm	make指定目录下的模块，但是不包括它们的依赖
mma	make当前目录下的所有模块，以及它们的依赖
mmma	make指定目录下的模块，以及它们的依赖
cgrep	只针对所有C/C++文件执行grep命令
ggrep	只针对所有gradle文件执行grep命令
jgrep	只针对所有Java文件执行grep命令
resgrep	只针对所有res/*.xml文件执行grep命令
mangrep	只针对所有AndroidManifest.xml文件执行grep命令
sepgrep	只针对所有sepolicy文件执行grep命令
sgrep	针对所有源代码文件执行grep命令
godir	转到包含指定文件的目录下

除了提供很多实用的函数外，envsetup.sh在文件的最后还会扫描和加载device和vendor目录下的vendorsetup.sh文件，具体如下所示：

```
for f in 'test -d device && find -L device -maxdepth 4 -name 'ven
         'test -d vendor && find -L vendor -maxdepth 4 -name 'ven
do
    echo "including $f"
    . $f
done
```

需要特别注意的是，上述脚本对vendorsetup.sh文件的扫描深度为4。由前面章节的学习我们知道，vendorsetup.sh会通过add_lunch_combo命令来为lunch添加一条加载项，如图3-14是*星手机的一个实例。

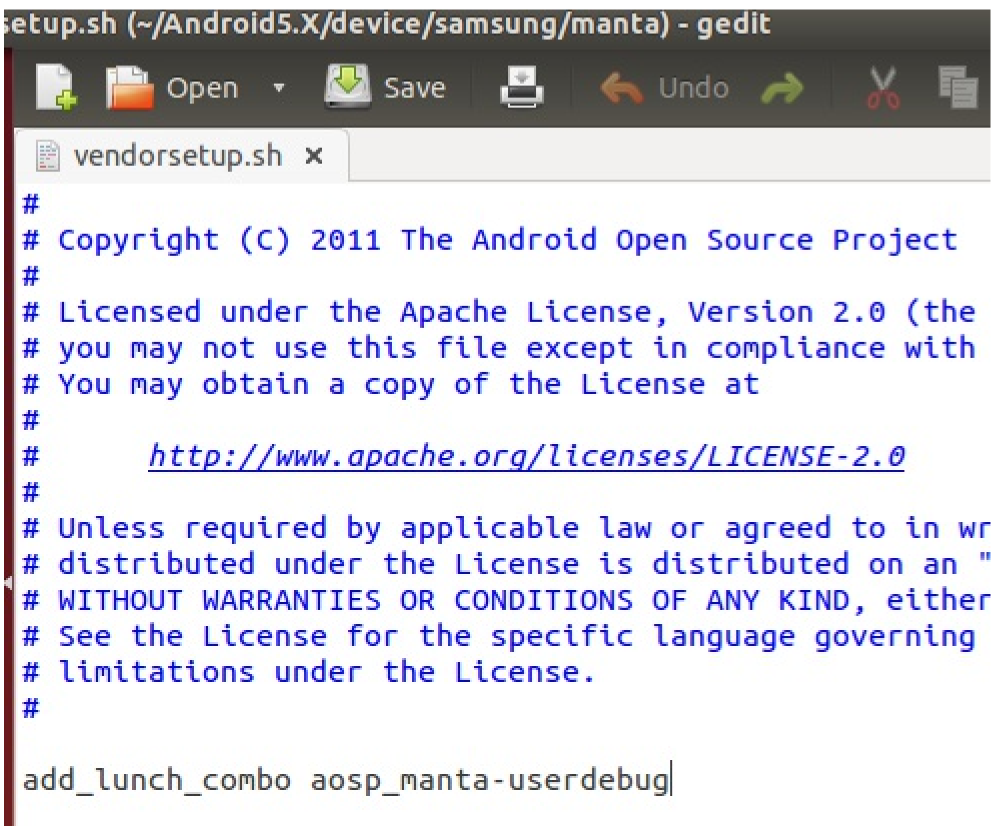

▲图3-14　vendorsetup.sh示例

当envsetup.sh执行结束后，将会打印出搜寻到的

vendorsetup.sh，如图3-15所示。

```
s@ubuntu:~/Android5.X$ . ./build/envsetup.sh
including device/asus/deb/vendorsetup.sh
including device/asus/flo/vendorsetup.sh
including device/asus/fugu/vendorsetup.sh
including device/asus/grouper/vendorsetup.sh
including device/asus/tilapia/vendorsetup.sh
including device/generic/mini-emulator-arm64/vendorsetup.sh
including device/generic/mini-emulator-armv7-a-neon/vendorsetup.sh
including device/generic/mini-emulator-mips/vendorsetup.sh
including device/generic/mini-emulator-x86_64/vendorsetup.sh
including device/generic/mini-emulator-x86/vendorsetup.sh
including device/htc/flounder/vendorsetup.sh
including device/lge/hammerhead/vendorsetup.sh
including device/lge/mako/vendorsetup.sh
including device/moto/shamu/vendorsetup.sh
including device/samsung/manta/vendorsetup.sh
including sdk/bash_completion/adb.bash
```

▲图3-15　打印的信息

3.4.2　lunch sdk-eng

完成envsetup.sh的初始化后，我们就可以执行下一步命令了，即lunch sdk-eng。

大家应该还记得lunch命令的用法：要么在lunch后加上product-variant参数，要么不带任何参数，从而让编译系统打印出当前可选的产品列表，如图3-16所示。

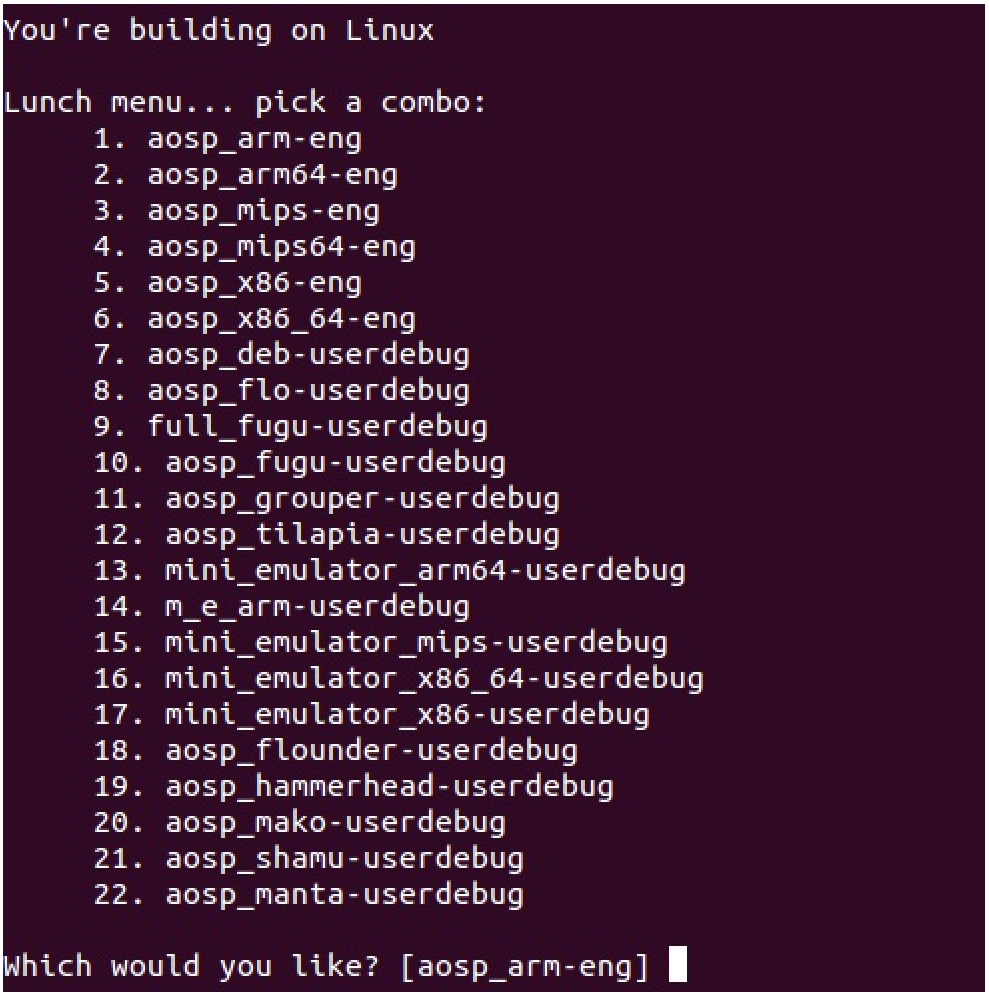

▲图3-16　产品的列表

看了上述列表，不少读者可能会有疑惑——编译SDK使用的命令lunch sdk-eng并没有在列表中，那么它是合法的吗？

答案是肯定的。实际上lunch提供的列表是由开发者在vendorsetup.sh或其他文件中通过add_lunch_combo提供的，并不是必需的；而真正的重点在于lunch product-variant在执行过程中如何验证product和variant的合法性。

（1）lunch针对product的合法性检查

```
function lunch()
{
    local answer
```

```
if [ "$1" ] ; then  ##如果ｌｕｎｃｈ命令带参数，则记录下来
   answer=$1
else
   print_lunch_menu  ##否则打印出产品列表供开发者选择
   echo -n "Which would you like? [aosp_arm-eng] "
   read answer  ##读取用户的选择
fi

local selection=

if [ -z "$answer" ]  ##如果用户什么也没选
then
   selection=aosp_arm-eng  ##默认选择一个
elif (echo -n $answer | grep -q -e "^ [0-9][0-9]*$")##如果是数
then
   if [ $answer -le ${#LUNCH_MENU_CHOICES[@]} ]##数字有效
   then
       selection=${LUNCH_MENU_CHOICES[$(($answer-1))]} ##读取
   fi
elif (echo -n $answer | grep -q -e "^[^\-][^\-]*-[^\-][^\-]*$
then
    selection=$answer
fi

if [ -z "$selection" ]    ##这时ｓｅｌｅｃｔｉｏｎ不应该为空了
then
    echo
    echo "Invalid lunch combo: $answer"
    return 1
fi

export TARGET_BUILD_APPS=

local product=$(echo -n $selection | sed -e "s/-.*$//")##从参
check_product $product  ##检验ｐｒｏｄｕｃｔ是否合法，下面我们会有
if [ $? -ne 0 ]##“$?”用于检查上一个函数的退出码，这里是指check_prod
then
   echo
   echo "** Don't have a product spec for: '$product'"
   echo "** Do you have the right repo manifest?"
   product=
fi

local variant=$(echo -n $selection | sed -e "s/^[^\-]*-//")#
check_variant $variant  ##检验ｖａｒｉａｎｔ是否合法，下面我们会有
if [ $? -ne 0 ]##“$?”用于检查上一个函数的退出码，这里是指check_vari
then
   echo
```

```
        echo "** Invalid variant: '$variant'"
        echo "** Must be one of ${VARIANT_CHOICES[@]}"
        variant=
    fi

    if [ -z "$product" -o -z "$variant" ]
    then
        echo
        return 1
    fi

    export TARGET_PRODUCT=$product  ##将结果值传递给全局变量
    export TARGET_BUILD_VARIANT=$variant
    export TARGET_BUILD_TYPE=release

    echo

    set_stuff_for_environment
    printconfig
}
```

可以看到，检查product的合法性主要依靠的是check_product这个函数，具体如下所示：

```
function check_product()
{
    T=$(gettop)
    if [ ! "$T" ]; then
       echo "Couldn't locate the top of the tree.  Try setting TO
       return
    fi
       TARGET_PRODUCT=$1 \
       TARGET_BUILD_VARIANT= \
       TARGET_BUILD_TYPE= \
       TARGET_BUILD_APPS= \
       get_build_var TARGET_DEVICE > /dev/null
    # hide successful answers, but allow the errors to show
}
```

这个函数看起来很简单，什么也没做，奥妙就在于最后的get_build_var TARGET_DEVICE。我们接下来看一下get_build_var又做了哪些工作。要特别注意的是，TARGET_PRODUCT被赋予了第1个参数值，即$product，在我们这个例子中就是sdk。

```
function get_build_var()
```

```
{
    T=$(gettop)##回到AOSP工程根目录
    if [ ! "$T" ]; then
       echo "Couldn't locate the top of the tree.  Try setting TO
       return
    fi
    (\cd $T; CALLED_FROM_SETUP=true BUILD_SYSTEM=build/core \
     command make --no-print-directory -f build/core/config.mk du
}
```

这个函数首先回到工程的根目录，然后为几个变量赋值，它们都将在后续过程中发挥作用。最后，它调用了make命令，执行的脚本是/build/core/config.mk，而且将目标对象设置为dumpvar-$1，其中$1即get_build_var的调用参数TARGET_DEVICE。那么这个TARGET_DEVICE的值是什么呢？

```
/*build/core/config.mk*/
…
include $(BUILD_SYSTEM)/envsetup.mk
…
include $(BUILD_SYSTEM)/combo/javac.mk
…
include $(BUILD_SYSTEM)/dumpvar.mk
```

可以看到，config.mk的主要目的如其名所示，就是为了做各种配置工作，而这其中非常重要的一步配置是通过envsetup.mk这个脚本完成的。读者应该特别注意，将这个envsetup.mk与之前提到的envsetup.sh区分开来：

```
/*build/core/envsetup.mk*/
…
include $(BUILD_SYSTEM)/product_config.mk
…
board_config_mk := \
     $(strip $(wildcard \
          $(SRC_TARGET_DIR)/board/$(TARGET_DEVICE)/BoardConfig.mk
          $(shell test -d device && find device -maxdepth 4 -path
          $(shell test -d vendor && find vendor -maxdepth 4 -path
     ))
```

从上面的脚本可以清楚地看到，BoardConfig.mk的赋值与TARGET_DEVICE有关系，因而后者一定要在前者之前被确定下来，更确切来讲就是在product_config.mk中了：

```
/*build/core/product_config.mk*/
…
include $(BUILD_SYSTEM)/node_fns.mk
include $(BUILD_SYSTEM)/product.mk
include $(BUILD_SYSTEM)/device.mk

ifneq ($(strip $(TARGET_BUILD_APPS)),)
# An unbundled app build needs only the core product makefiles.
all_product_configs := $(call get-product-makefiles,\
    $(SRC_TARGET_DIR)/product/AndroidProducts.mk)
else
# Read in all of the product definitions specified by the Android
# files in the tree.
all_product_configs := $(get-all-product-makefiles)
endif
…
ifneq (,$(filter product-graph dump-products, $(MAKECMDGOALS)))
# Import all product makefiles.
$(call import-products, $(all_product_makefiles))
else
# Import just the current product.
ifndef current_product_makefile ##如果出现错误，编译脚本就会停止，这也是
$(error Can not locate config makefile for product "$(TARGET_PROD
endif
ifneq (1,$(words $(current_product_makefile)))
$(error Product "$(TARGET_PRODUCT)" ambiguous: matches $(current_
endif
$(call import-products, $(current_product_makefile))
endif  # Import all or just the current product makefile
TARGET_DEVICE := $(PRODUCTS.$(INTERNAL_PRODUCT).PRODUCT_DEVICE)
…
```

脚本node_fns.mk、product.mk和device.mk引入了很多函数定义，它们会在后续查找产品定义的操作中产生作用。比如接下来的get-product-makefiles和get-all-product-makefiles的定义就在product.mk中。

如果TARGET_BUILD_APPS不为空，那么证明本次并不是全编译，所以只要把核心的产品定义引用进来就可以了。核心产品是由$(SRC_TARGET_DIR)/product/AndroidProducts.mk提供的，即/build/target/product/AndroidProducts.mk：

```
ifneq ($(TARGET_BUILD_APPS),)
PRODUCT_MAKEFILES := \
    $(LOCAL_DIR)/aosp_arm.mk \
```

```
    $(LOCAL_DIR)/full.mk \
    $(LOCAL_DIR)/generic_armv5.mk \
    $(LOCAL_DIR)/aosp_x86.mk \
    $(LOCAL_DIR)/full_x86.mk \
    $(LOCAL_DIR)/aosp_mips.mk \
    $(LOCAL_DIR)/full_mips.mk \
    $(LOCAL_DIR)/aosp_arm64.mk \
    $(LOCAL_DIR)/aosp_mips64.mk \
    $(LOCAL_DIR)/aosp_x86_64.mk
else
PRODUCT_MAKEFILES := \
    $(LOCAL_DIR)/core.mk \
    $(LOCAL_DIR)/generic.mk \
    $(LOCAL_DIR)/generic_x86.mk \
    $(LOCAL_DIR)/generic_mips.mk \
    $(LOCAL_DIR)/aosp_arm.mk \
    $(LOCAL_DIR)/full.mk \
    $(LOCAL_DIR)/aosp_x86.mk \
    $(LOCAL_DIR)/full_x86.mk \
    $(LOCAL_DIR)/aosp_mips.mk \
    $(LOCAL_DIR)/full_mips.mk \
    $(LOCAL_DIR)/aosp_arm64.mk \
    $(LOCAL_DIR)/aosp_mips64.mk \
    $(LOCAL_DIR)/aosp_x86_64.mk \
    $(LOCAL_DIR)/full_x86_64.mk \
    $(LOCAL_DIR)/sdk_phone_armv7.mk \
    $(LOCAL_DIR)/sdk_phone_x86.mk \
    $(LOCAL_DIR)/sdk_phone_mips.mk \
    $(LOCAL_DIR)/sdk_phone_arm64.mk \
    $(LOCAL_DIR)/sdk_phone_x86_64.mk \
    $(LOCAL_DIR)/sdk_phone_mips64.mk \
    $(LOCAL_DIR)/sdk.mk \
    $(LOCAL_DIR)/sdk_x86.mk \
    $(LOCAL_DIR)/sdk_mips.mk \
    $(LOCAL_DIR)/sdk_arm64.mk \
    $(LOCAL_DIR)/sdk_x86_64.mk
endif
```

可以看到，在确定产品定义时仍然会区分当前是否是全编译的情况。不管是哪种情况，收集到的产品定义项都会放到PRODUCT_MAKEFILES中。需要特别注意的是，PRODUCT_MAKEFILES实际上只是一个文件列表的集合，那么这些文件的具体内容会在什么时候进行解析呢？答案就是前述的product_config.mk中的get-product-makefiles和get-all-product-makefiles。这两个函数会逐一取出PRODUCT_MAKEFILES列表中的每一个文件名，组成一个路径，然后通过

include将脚本中的内容读取进来。我们以sdk.mk这个列表项为例，它的部分内容节选如下：

```
/*sdk.mk*/
$(call inherit-product, $(SRC_TARGET_DIR)/product/sdk_phone_armv7
PRODUCT_NAME := sdk

/*sdk_phone_armv7.mk*/
$(call inherit-product, $(SRC_TARGET_DIR)/product/sdk_base.mk)
# Overrides
PRODUCT_BRAND := generic
PRODUCT_NAME := sdk_phone_armv7
PRODUCT_DEVICE := generic

/*sdk_base.mk*/
PRODUCT_PROPERTY_OVERRIDES :=
PRODUCT_PACKAGES := \
     ApiDemos \
     CubeLiveWallpapers \
     CustomLocale \
     Development \
     DevelopmentSettings \
     Dialer \
     EmulatorSmokeTests \
…
```

上述的内容可谓“环环相扣”，颇有点“继承”的关系。这种实现方式可以很好地分离各个脚本的职责，值得大家借鉴。

再回到前面的TARGET_DEVICE的赋值中来。还记得product_config.mk中的最后一行是怎么给TARGET_DEVICE赋值的吗？我们再把它列出来：

```
TARGET_DEVICE := $(PRODUCTS.$(INTERNAL_PRODUCT).PRODUCT_DEVICE)
```

大家肯定会有疑问，这个PRODUCTS又是从何而来的呢？它是对所有产品的一个记录集。具体而言，就是调用了product.mk中的import-products，后者又引用了import-nodes——这个函数则会对PRODUCTS和DEVICES等变量进行赋值，从而才能保证TARGET_DEVICE可以取到正确的值。

总结来说，对product的整个检查过程无非是做了两件事：

- 对各种变量进行赋值，保证后续编译的正常运行；
- 在出现错误时直接终止脚本运行，从而有效保证了product的准确性。这一点才是体现“合法性检查”的关键核心;而且当check_product检查过程中出现错误时，$?不为0，这样函数退出后就可以通过这一变量进行出错判断，如下所示：

```
if [ $? -ne 0 ]
    then
       echo
       echo "** Don't have a product spec for: '$product'"
       echo "** Do you have the right repo manifest?"
       product=
    fi
```

（2）lunch对variant合法性的检查

和check_product类似，check_variant用于检查variant的合法性，在我们这个例子中就是“eng”：

```
/*/build/envsetup.sh*/
VARIANT_CHOICES=(user userdebug eng)
function check_variant()
{
    for v in ${VARIANT_CHOICES[@]}
    do
        if [ "$v" = "$1" ]
        then
            return 0
        fi
    done
    return 1
}
```

可以看到，check_variant的实现相当简单，直接从VARIANT_CHOICES数组（只有user、userdebug和eng三种）中逐一取出元素进行比较，一旦有匹配的就返回0；函数结束时仍然没有找到匹配的则返回1。后面一种情况下，$? -ne 0会被判定为真，因而脚本在执行过程中将打印出错误，表示当前variant是无效的。

3.4.3 make sdk

本小节我们重点分析make sdk这一命令的处理流程，它和编译各种系统image有不小的差异。

不过和其他image一样，sdk的编译脚本主体在Main.mk中。我们节选出其中的关键部分：

```
/*build/core/Main.mk*/

is_sdk_build :=       ##用于标志当前是否是sdk编译

ifneq ($(filter sdk win_sdk sdk_addon,$(MAKECMDGOALS)),)##判断是否
is_sdk_build := true
endif
…
ifdef is_sdk_build
# Detect if we want to build a repository for the SDK
sdk_repo_goal := $(strip $(filter sdk_repo,$(MAKECMDGOALS)))
MAKECMDGOALS := $(strip $(filter-out sdk_repo,$(MAKECMDGOALS)))

ifneq ($(words $(filter-out $(INTERNAL_MODIFIER_TARGETS) checkbui
target-files-package,$(MAKECMDGOALS))),1)
$(error The 'sdk' target may not be specified with any other targ
endif

# TODO: this should be eng I think.  Since the sdk is built from
# variant.
tags_to_install := debug eng
ADDITIONAL_BUILD_PROPERTIES += xmpp.auto-presence=true
ADDITIONAL_BUILD_PROPERTIES += ro.config.nocheckin=yes
else # !sdk
endif
…
# Bring in all modules that need to be built.
ifeq ($(HOST_OS),windows)
SDK_ONLY := true
endif

ifeq ($(SDK_ONLY),true)
include $(TOPDIR)sdk/build/windows_sdk_whitelist.mk
include $(TOPDIR)development/build/windows_sdk_whitelist.mk

# Exclude tools/acp when cross-compiling windows under linux
ifeq ($(findstring Linux,$(UNAME)),)
subdirs += build/tools/acp
endif
```

```
else # !SDK_ONLY
#
# Typical build; include any Android.mk files we can find.
#
subdirs := $(TOP)
FULL_BUILD := true
endif # !SDK_ONLY
…
include $(BUILD_SYSTEM)/Makefile
…
.PHONY: sdk
ALL_SDK_TARGETS := $(INTERNAL_SDK_TARGET)
sdk: $(ALL_SDK_TARGETS)
$(call dist-for-goals,sdk win_sdk, \
    $(ALL_SDK_TARGETS) \
    $(SYMBOLS_ZIP) \
    $(INSTALLED_BUILD_PROP_TARGET) \
)
```

上面这段脚本的关键之一在于dist-for-goals这个函数，它的定义如下：

```
/*build/core/distdir.mk*/
define dist-for-goals
$(foreach file,$(2), \
  $(eval fw := $(subst :,$(space),$(file))) \
  $(eval src := $(word 1,$(fw))) \
  $(eval dst := $(word 2,$(fw))) \
  $(eval dst := $(if $(dst),$(dst),$(notdir $(src)))) \
  $(if $(filter $(_all_dist_src_dst_pairs),$(src):$(dst)),\ ##如果
    $(eval $(call add-dependency,$(1),$(DIST_DIR)/$(dst))),\ ##那
    $(eval $(call copy-one-dist-file,\  ##如果没有处理过的情况
      $(src),$(DIST_DIR)/$(dst),$(1)))\
      $(eval _all_dist_src_dst_pairs += $(src):$(dst))\
  )\
)
endef
```

这个函数用于记录goal所需要的全部src:dst对。它带有两个参数，即：

- $(1)

代表目标对象goal的集合，比如上面脚本中对应的是sdk win_sdk。

- $(2)

为上述参数中的goal指定所需的dist文件列表。如果dist文件中包含冒号，那么“:”之后的表示它在dist文件夹中的名称。

dist-for-goals函数会遍历$(2)中dist文件列表的所有file，并执行以下操作。

（1）将file包含的冒号替换成空格。其中subst和eval都是makefile提供的函数，eval的函数原型为：

```
$(eval arg).
```

这个函数比较特殊，它可以将其他变量和函数的解析结果添加到make的语法规则中。为了达到这一目标，eval的参数会被扩展两次：第一次是由eval函数来扩展，然后当它被作为makefile语法解析时又会被扩展一次。

（2）fw的空格前半部分是src，后半部分是dst。

（3）if函数的语法规则为：

```
$(if <condition>,<then-part> ) 或者 $(if <condition>,<then-part>,<
```

所以$(if $(dst),$(dst),$(notdir $(src)))的意思就是如果dst不为空，那么就取dst作为结果；否则取src路径中的文件名作为结果。这样就保证了用户没有特别指定dst的情况下它有一个默认值。

（4）filter函数的语法规则为：

```
$(filter <pattern…>,<text> )
```

即应用pattern模式来过滤text中的内容，允许有多个pattern存在。

所以$(filter $(_all_dist_src_dst_pairs), $(src):$(dst))用于判断src:dst这个组合对在_all_dist_src_dst_pairs中是否已经存在。如果是的话，接下来就只调用add-dependency来为goal添加依赖关系；否则就需要将其复制到dst中。

我们再回到main.mk中。可以看到，sdk这个目标依赖于$(ALL_SDK_TARGETS)，即$(INTERNAL_SDK_TARGET)，那么后面这个变量又是从哪来的呢？

答案就是build/core/Makefile，它会被include到main.mk中：

```
include $(BUILD_SYSTEM)/Makefile
```

不光是sdk，实际上大部分系统image的依赖关系都是在Makefile这个文件中指定的，可以说它是这些目标生成规则的“集大成者”。我们看一下与sdk相关的部分：

```
/*build/core/Makefile*/
INTERNAL_SDK_TARGET := $(sdk_dir)/$(sdk_name).zip ####Comment 1
…
$(INTERNAL_SDK_TARGET): $(deps)####Comment 2
	@echo "Package SDK: $@"
	$(hide) rm -rf $(PRIVATE_DIR) $@
	…
	if [ $$FAIL ]; then exit 1; fi ##如果执行过程中产生错误，直接结束
	$(hide) echo $(notdir $(SDK_FONT_DEPS)) | tr " " "\n"  > $(S
	$(hide) ( \
		ATREE_STRIP="strip -x" \
		$(HOST_OUT_EXECUTABLES)/atree \ ####Comment 3
		$(addprefix -f ,$(PRIVATE_INPUT_FILES)) \
			-m $(PRIVATE_DEP_FILE) \
			-I . \
			-I $(PRODUCT_OUT) \
			-I $(HOST_OUT) \
			-I $(TARGET_COMMON_OUT_ROOT) \
			-v "PLATFORM_NAME=android-$(PLATFORM_VERSION)" \
			-v "OUT_DIR=$(OUT_DIR)" \
			-v "HOST_OUT=$(HOST_OUT)" \
			-v "TARGET_ARCH=$(TARGET_ARCH)" \
			-v "TARGET_CPU_ABI=$(TARGET_CPU_ABI)" \
			-v "DLL_EXTENSION=$(HOST_SHLIB_SUFFIX)" \
			-v "FONT_OUT=$(SDK_FONT_TEMP)" \
			-o $(PRIVATE_DIR) && \
	$(PRIVATE_DIR)/system-images/android-$(PLATFORM_VERSION)/$(T
		cp -f $(tools_notice_file_txt) $(PRIVATE_DIR)/platform-
		HOST_OUT_EXECUTABLES=$(HOST_OUT_EXECUTABLES) HOST_OS=$(
			development/build/tools/sdk_clean.sh $(PRIVATE_DIR
		chmod -R ug+rwX $(PRIVATE_DIR) && \
		cd $(dir $@) && zip -rq $(notdir $@) $(PRIVATE_NAME) \
	) || ( rm -rf $(PRIVATE_DIR) $@ && exit 44 )
```

Comment 1：将INTERNAL_SDK_TARGET赋值为$(sdk_dir)/$(sdk_name).zip，其中sdk_dir指的是$(HOST_OUT)/sdk/$(TARGET_PRODUCT)，即/out/host/sdk/$(TARGET_PRODUCT)；而sdk_name则为 android-sdk_$(FILE_NAME_TAG)，典型情况下的值为：

```
#     linux-x86   --> android-sdk_12345_linux-x86
#     darwin-x86  --> android-sdk_12345_mac-x86
#     windows-x86 --> android-sdk_12345_windows
```

Comment 2：INTERNAL_SDK_TARGET := $(sdk_dir)/$(sdk_name).zip，下面是这个变量在典型情况下的值为：out/host/linux-x86/sdk/sdk/android-sdk_eng.s_linux-x86.zip。

由前面的分析可知，sdk这个伪目标依赖于INTERNAL_SDK_TARGET，后者则实际上依赖于$(deps)——这个变量是一个生成物的列表，如下截图是部分节选：

```
deps=out/target/product/generic/obj/NOTICE.txt out/host/linux-x86/obj/
NOTICE.txt out/target/common/docs/offline-sdk-timestamp out/target/product/
generic/sdk-symbols-eng.s.zip out/target/product/generic/system.img out/target/
product/generic/userdata.img out/target/product/generic/ramdisk.img out/target/
product/generic/sdk/sdk-build.prop out/target/product/generic/system/
build.prop  out/target/product/generic/system/bin/monkey out/target/product/
generic/system/usr/share/bmd/RFFspeed_501.bmd out/target/product/generic/system/
usr/share/bmd/RFFstd_501.bmd out/target/product/generic/system/bin/bmgr out/
target/product/generic/system/bin/ime out/target/product/generic/system/bin/
input out/target/product/generic/system/bin/pm out/target/product/generic/
system/bin/svc  out/host/linux-x86/bin/aapt out/host/linux-x86/bin/adb out/host/
linux-x86/bin/aidl out/host/linux-x86/bin/backtrace_test32 out/host/linux-x86/
bin/backtrace_test64 out/host/linux-x86/bin/bcc out/host/linux-x86/bin/
bcc_compat out/host/linux-x86/bin/dalvikvm out/host/linux-x86/bin/dalvikvm32
out/host/linux-x86/bin/dalvikvm64 out/host/linux-x86/bin/dex2oat out/host/linux-
x86/bin/dexdeps out/host/linux-x86/bin/dexdump out/host/linux-x86/bin/dexlist
out/host/linux-x86/bin/dmtracedump out/host/linux-x86/bin/dx out/host/linux-x86/
bin/etc1tool out/host/linux-x86/bin/fastboot out/host/linux-x86/bin/
hierarchyviewer1 out/host/linux-x86/bin/hprof-conv out/host/linux-x86/bin/ld.mc
out/host/linux-x86/bin/llvm-rs-cc out/host/linux-x86/bin/make_ext4fs out/host/
linux-x86/bin/oatdump out/host/linux-x86/bin/patchoat out/host/linux-x86/bin/
simpleperf out/host/linux-x86/bin/split-select out/host/linux-x86/bin/sqlite3
out/host/linux-x86/bin/tzdatacheck out/host/linux-x86/bin/zipalign out/host/
linux-x86/framework/commons-compress-1.0.jar out/host/linux-x86/framework/
dexdeps.jar out/host/linux-x86/framework/dx.jar out/host/linux-x86/framework/
emmalib.jar out/host/linux-x86/framework/hierarchyviewer.jar out/host/linux-x86/
```

它代表了生成sdk需要编译的所有中间产物。那么这么多文件内容又是如何产生的呢？

```
/*build/core/Makefile*/

deps := \
     $(target_notice_file_txt) \
     $(tools_notice_file_txt) \
     $(OUT_DOCS)/offline-sdk-timestamp \
     $(SYMBOLS_ZIP) \
     $(INSTALLED_SYSTEMIMAGE) \
     $(INSTALLED_USERDATAIMAGE_TARGET) \
     $(INSTALLED_RAMDISK_TARGET) \
     $(INSTALLED_SDK_BUILD_PROP_TARGET) \
     $(INSTALLED_BUILD_PROP_TARGET) \
     $(ATREE_FILES) \
     $(sdk_atree_files) \
     $(HOST_OUT_EXECUTABLES)/atree \
     $(HOST_OUT_EXECUTABLES)/line_endings \
     $(SDK_FONT_DEPS)
```

我们知道，SDK包含的东西比较多，除了各种文档和framework中间件（android.jar）外，还有平台工具、字体，以及各种image文件（如system和userdata，这些都是模拟器运行所必需的）等。

因为deps变量所涉及的内容比较多，我们接下来会挑选android.jar这个最重要的文件作为例子进行讲解，读者也可以根据需要自行分析其他产物。

Comment 3：可以看到deps变量中有不少与atree相关的文件，它们是sdk最终产物的描述文件。比如下面这个范例：

```
/*development/build/sdk.atree*/
…
# host tools from out/host/$(HOST_OS)-$(HOST_ARCH)/
bin/adb                                  strip platform-tools/adb
bin/fastboot                             strip platform-tools/fast
bin/sqlite3                              strip platform-tools/sqli
bin/dmtracedump                          strip platform-tools/dmtr
bin/etc1tool                             strip platform-tools/etc1
bin/hprof-conv                           strip platform-tools/hpro
```

Atree文件中的内容分为两列，左边一列表达的是“source”，右边则是“destination”。大家应该已经想到了，既然有atree格式的描

述文件，那么一定会有工具来解析这些格式。

完成这一任务的是atree，它所支持的主要参数选项及释义如表3-8所示。

表3-8　工具atree参数选项表

Option	Description
-f FILELIST	FILELIST是文件列表，其中的文件用于记录需要被复制的一系列文件名
-I INPUTDIR	指定基准目录，帮助atree查找上述的被复制文件
-o OUTPUTDIR	指定复制的目标路径
-l	使用硬链接，而不是真的复制文件
-m DEPENDENCY	输出一个make格式的文件
-v VAR=VAL	在读取输入文件过程中，将$VAR替换成VAL
-d	调试模式，用于输出额外的信息

对照上述的参数选项列表，我们再来重点看下Comment 3部分的实现：

```
ATREE_STRIP="strip -x" \
          $(HOST_OUT_EXECUTABLES)/atree \ ####Comment 3
          $(addprefix -f ,$(PRIVATE_INPUT_FILES)) \ ####-f选项
               -m $(PRIVATE_DEP_FILE) \
               -I . \
               -I $(PRODUCT_OUT) \
               -I $(HOST_OUT) \
               -I $(TARGET_COMMON_OUT_ROOT) \
               -v "PLATFORM_NAME=android-$(PLATFORM_VERSION)" \
               -v "OUT_DIR=$(OUT_DIR)" \
               -v "HOST_OUT=$(HOST_OUT)" \
               -v "TARGET_ARCH=$(TARGET_ARCH)" \
               -v "TARGET_CPU_ABI=$(TARGET_CPU_ABI)" \
               -v "DLL_EXTENSION=$(HOST_SHLIB_SUFFIX)" \
               -v "FONT_OUT=$(SDK_FONT_TEMP)" \
               -o $(PRIVATE_DIR) && \
```

其中，-f选项所带的参数是$(PRIVATE_INPUT_FILES)，后者因为是一个文件列表，所以需要通过addprefix为它们全部加上-f选项。那么$(PRIVATE_INPUT_FILES)具体包含了哪些文件呢？

由前面的脚本文件不难分析出，$(PRIVATE_INPUT_FILES)实际上等价于sdk_atree_files，进一步来讲，就是包含了如下的文件：

```
sdk_atree_files := \
     $(atree_dir)/sdk.exclude.atree \
     $(atree_dir)/sdk-$(HOST_OS)-$(SDK_HOST_ARCH).atree
…
$(atree_dir)/sdk-android-$(TARGET_CPU_ABI).atree
…
$(atree_dir)/sdk.atree
```

其中atree_dir指定的是development/build，这个目录下包含了不少atree文件，如下所示：

- sdk.atree
- sdk.exclude.atree
- sdk-android-arm64-v8a.atree
- sdk-android-armeabi.atree
- sdk-android-armeabi-v7a.atree
- sdk-android-mips.atree
- sdk-android-x86.atree
- sdk-android-x86_64.atree
- sdk-darwin-x86.atree
- sdk-linux-x86.atree
- sdk-windows-x86.atree

以我们关心的android.jar为例，与它相对应的描述语句如下所示：

```
# the uper-jar file that apps link against. This is the public AP
${OUT_DIR}/target/common/obj/PACKAGING/android_jar_intermediates/
platforms/${PLATFORM_NAME}/android.jar
```

也就是说，通过atree文件可以将out目录下编译生成的android.jar复制到sdk目标路径下的platforms/${PLATFORM_NAME}/文件夹中。现在的问题转变为，android.jar又是如何生成的呢？

答案就在development/build/Android.mk中，我们一起来看一下：

```
# ===== SDK jar file of stubs =====
# A.k.a the "current" version of the public SDK (android.jar insi
sdk_stub_name := android_stubs_current
stub_timestamp := $(OUT_DOCS)/api-stubs-timestamp
include $(LOCAL_PATH)/build_android_stubs.mk

.PHONY: android_stubs
android_stubs: $(full_target)
…
# android.jar is what we put in the SDK package.
android_jar_intermediates := $(TARGET_OUT_COMMON_INTERMEDIATES)/P
android_jar_full_target := $(android_jar_intermediates)/android.j

$(android_jar_full_target): $(full_target)
     @echo Package SDK Stubs: $@
     $(hide)mkdir -p $(dir $@)
     $(hide)$(ACP) $< $@
```

```
ALL_SDK_FILES += $(android_jar_full_target)
```

其中android_jar_full_target是android.jar中out目录中的绝对路径，即$(TARGET_OUT_COMMON_INTERMEDIATES)/PACKAGING/android_jar_interr 而且它依赖于full_target变量——从名称上可以猜到，这个变量用于记录所有android.jar包中所需的文件。根据make的规则，一旦full_target比目标android_jar_full_target新，那么就会执行以下的命令，包括：

- 打印出"Package SDK Stubs:[目标对象]"。
- 新建android_jar_full_target所指向的目录，即$(TARGET_OUT_COMMON_INTERMEDIATES)/PACKAGING/android_jar_intermediates。
- 调用$(ACP)执行实际的复制和打包工作。

$(ACP)是Android编译系统提供的专门用于跨平台复制的一个工具，源码路径是/build/tools/acp。它的用法如下：

```
acp [OPTION]  SOURCE  DEST
```

那么SOURCE，即full_target包含了哪些内容呢？

我们需要在build_android_stubs.mk中寻找答案，如下所示：

```
/*development/build/build_android_stubs.mk*/
# Build an SDK jar file out of the generated stubs
intermediates := $(TARGET_OUT_COMMON_INTERMEDIATES)/JAVA_LIBRARIE
full_target := $(intermediates)/classes.jar
src_dir := $(intermediates)/src
classes_dir := $(intermediates)/classes
framework_res_package := $(call intermediates-dir-for,APPS,framew

$(full_target): PRIVATE_SRC_DIR := $(src_dir)
$(full_target): PRIVATE_INTERMEDIATES_DIR := $(intermediates)
$(full_target): PRIVATE_CLASS_INTERMEDIATES_DIR := $(classes_dir)
$(full_target): PRIVATE_FRAMEWORK_RES_PACKAGE := $(framework_res_

$(full_target): $(stub_timestamp) $(framework_res_package)
     @echo Compiling SDK Stubs: $@
     $(hide) rm -rf $(PRIVATE_CLASS_INTERMEDIATES_DIR)  ###Step1
```

```
$(hide) mkdir -p $(PRIVATE_CLASS_INTERMEDIATES_DIR)
$(hide) find $(PRIVATE_SRC_DIR) -name "*.java" > \
   $(PRIVATE_INTERMEDIATES_DIR)/java-source-list ###Step2
$(hide) $(TARGET_JAVAC) -encoding ascii -bootclasspath "" \
          -g $(xlint_unchecked) \
          -extdirs "" -d $(PRIVATE_CLASS_INTERMEDIATES_DIR)
          \@$(PRIVATE_INTERMEDIATES_DIR)/java-source-list \
     || ( rm -rf $(PRIVATE_CLASS_INTERMEDIATES_DIR) ; exit 4
$(hide) if [ ! -f $(PRIVATE_FRAMEWORK_RES_PACKAGE) ]; then \
     echo Missing file $(PRIVATE_FRAMEWORK_RES_PACKAGE); \
     rm -rf $(PRIVATE_CLASS_INTERMEDIATES_DIR); \
     exit 1; \
fi; ###Step4
$(hide) unzip -qo $(PRIVATE_FRAMEWORK_RES_PACKAGE) -d $(PRIV
$(hide) (cd $(PRIVATE_CLASS_INTERMEDIATES_DIR) && rm -rf cla
$(hide) mkdir -p $(dir $@)
$(hide) jar -cf $@ -C $(PRIVATE_CLASS_INTERMEDIATES_DIR) .
$(hide) jar -u0f $@ -C $(PRIVATE_CLASS_INTERMEDIATES_DIR) re
```

脚本build_android_stubs.mk有两个类似于入参的变量，分别是：

（1）sdk_stub_name：SDK stub的名称。Stub源代码应该已经生成在$(TARGET_OUT_COMMON_INTERMEDIATES)/JAVA_LIBRARIES/$(sdk_stub_na目录中。在这个例子中对应的就是$(TARGET_OUT_COMMON_INTERMEDIATES)/JAVA_LIBRARIES/android_stubs

（2）stub_timestamp：生成的源码所依赖的时间戳文件

总的来说，build_android_stubs.mk脚本的目标是编译一个classes.jar，换句话讲就是我们需要的android.jar。而被编译的所有源文件必须已经生成到上述的android_stubs_current_intermediates文件夹中了，这是由droiddoc.mk来完成的，我们后续将会有进一步分析。

现在先来看一下如何编译和打包classes.jar（即脚本中的full_target变量）。

Step1. 首先通过整个文件夹删除来清理掉$(intermediates)/classes目录中的内容，然后再重新创建这个文件夹。

Step2. 查找$(intermediates)/src目录下以“java”为后缀的所有文件，并把结果记录到$(intermediates)/java-source-list中，以供后续使用。

Step3. 这是关键的一个步骤，即通过调用javac来完成编译工作。其中encoding参数用于指明文件的编码格式，以保证编译能顺利进行。其他参数的官方释义如图3-17所示。

```
-g                         Generate all debugging info
-g:none                    Generate no debugging info
-g:{lines,vars,source}     Generate only some debugging info
-nowarn                    Generate no warnings
-verbose                   Output messages about what the compiler is doing
-deprecation               Output source locations where deprecated APIs are used
-classpath <path>          Specify where to find user class files and annotation processors
-cp <path>                 Specify where to find user class files and annotation processors
-sourcepath <path>         Specify where to find input source files
-bootclasspath <path>      Override location of bootstrap class files
-extdirs <dirs>            Override location of installed extensions
-endorseddirs <dirs>       Override location of endorsed standards path
-proc:{none,only}          Control whether annotation processing and/or compilation is done.
-processor <class1>[,<class2>,<class3>...] Names of the annotation processors to run; bypasses default discovery process
-processorpath <path>      Specify where to find annotation processors
-d <directory>             Specify where to place generated class files
-s <directory>             Specify where to place generated source files
-implicit:{none,class}     Specify whether or not to generate class files for implicitly referenced files
-encoding <encoding>       Specify character encoding used by source files
-source <release>          Provide source compatibility with specified release
-target <release>          Generate class files for specific VM version
-version                   Version information
-help                      Print a synopsis of standard options
-Akey[=value]              Options to pass to annotation processors
-X                         Print a synopsis of nonstandard options
-J<flag>                   Pass <flag> directly to the runtime system
-Werror                    Terminate compilation if warnings occur
@<filename>                Read options and filenames from file
```

▲图3-17　官方释义

最后通过@<filename>来把前一步生成的java-source-list中记录的所有Java文件读取出来，然后执行编译过程，中间文件输出到$(intermediates)/classes中。

Step4. 如果PRIVATE_FRAMEWORK_RES_PACKAGE文件缺失，则终止操作并报错。

Step5. 这一步主要是针对前述的步骤进行清理和打包工作。

首先将framework_res_package所指向的apk通过unzip命令进行解压，结果也同样输出到$(intermediates)/classes中。在以后章节的学习中我们会发现，apk实际上就是zip包。大家可以尝试在Windows操作系统下通过WinRAR等类似软件打开一个实际的apk自行验证下。紧接着删除掉解压后的classes.dex和META-INF文件夹，换言之我们要的是apk中的res目录和resources.arsc。

一切准备就绪，现在就只剩下打包了。大家应该已经猜到了，classes.jar就是$(intermediates)/ classes文件夹内容的集成。具体操作分为两步，即：

```
jar -cf $@ -C $(PRIVATE_CLASS_INTERMEDIATES_DIR) .
```

创建classes.jar文件，然后将$(intermediates)/classes内容打包进去。

```
jar -u0f $@ -C $(PRIVATE_CLASS_INTERMEDIATES_DIR) resources.
```

更新jar包。

接下来我们再分析一下$(intermediates)/src中的源文件是如何生成的。

大家可以先思考一下，最有可能生成stub source的脚本是哪一个？回答这个问题，要先了解android.jar中的内容是什么。我们来看图3-18所示的界面。

▲图3-18　android.jar中包含的内容

是不是感觉非常熟悉？没错，它们和framework的组成基本上是一致的，只不过后者包含了实现体，而android.jar只是“空壳”，即Stub（桩），如图3-19所示。

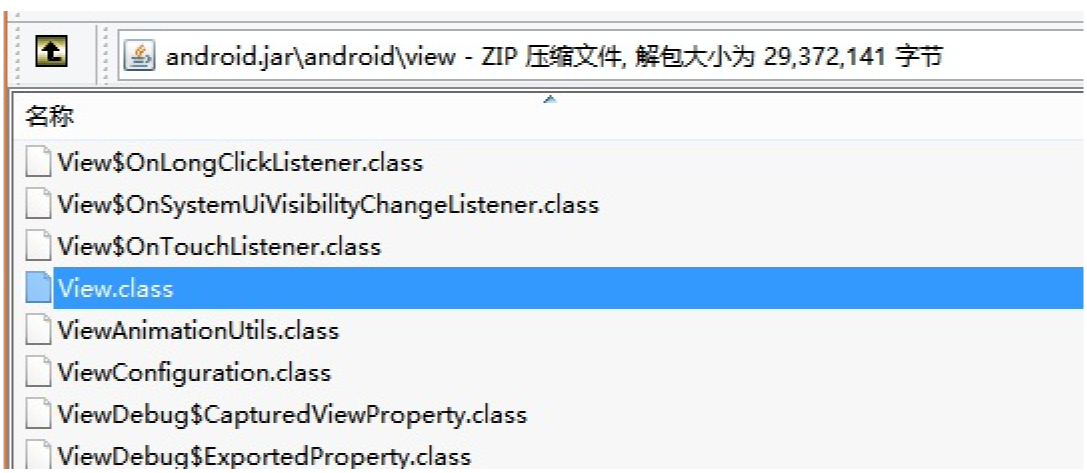

```
public View(Context context) {
    throw new RuntimeException("Stub!");
}

public View(Context context, AttributeSet attrs) {
    throw new RuntimeException("Stub!");
}

public View(Context context, AttributeSet attrs, int defStyleAttr) {
    throw new RuntimeException("Stub!");
}

public View(Context context, AttributeSet attrs, int defStyleAttr, int defStyleRes) {
    throw new RuntimeException("Stub!");
}

public String toString() {
    throw new RuntimeException("Stub!");
}
```

▲图3-19　android.jar中不包含实现体
（左：android/view目录下的View.class　右：View.class中的所有函数体实现都只是抛出一个异常。）

所以生成android.jar所需Stub源码的地方很可能在framework中，即/frameworks/base/ Android.mk。我们来实际验证一下：

```
# ====  the system api stubs ===================================
include $(CLEAR_VARS)

LOCAL_SRC_FILES:=$(framework_docs_LOCAL_API_CHECK_SRC_FILES)
LOCAL_INTERMEDIATE_SOURCES:=$(framework_docs_LOCAL_INTERMEDIATE_S
LOCAL_JAVA_LIBRARIES:=$(framework_docs_LOCAL_API_CHECK_JAVA_LIBRA
LOCAL_MODULE_CLASS:=$(framework_docs_LOCAL_MODULE_CLASS)
LOCAL_DROIDDOC_SOURCE_PATH:=$(framework_docs_LOCAL_DROIDDOC_SOURC
LOCAL_DROIDDOC_HTML_DIR:=$(framework_docs_LOCAL_DROIDDOC_HTML_DIR
LOCAL_ADDITIONAL_JAVA_DIR:=$(framework_docs_LOCAL_API_CHECK_ADDIT
LOCAL_ADDITIONAL_DEPENDENCIES:=$(framework_docs_LOCAL_ADDITIONAL_

LOCAL_MODULE := system-api-stubs

LOCAL_DROIDDOC_OPTIONS:=\
          $(framework_docs_LOCAL_DROIDDOC_OPTIONS) \
          -stubs $(TARGET_OUT_COMMON_INTERMEDIATES)/JAVA_LIBRARIE
          -showAnnotation android.annotation.SystemApi \
```

```
        -api $(INTERNAL_PLATFORM_SYSTEM_API_FILE) \
        -removedApi $(INTERNAL_PLATFORM_SYSTEM_REMOVED_API_FILE
        -nodocs

LOCAL_DROIDDOC_CUSTOM_TEMPLATE_DIR:=build/tools/droiddoc/template

LOCAL_UNINSTALLABLE_MODULE := true
include $(BUILD_DROIDDOC)
```

果然如此。具体生成stub借助的是droiddoc，也就是BUILD_DROIDDOC变量所指向的droiddoc.mk：

```
/*build/core/config.mk*/
…
BUILD_DROIDDOC:= $(BUILD_SYSTEM)/droiddoc.mk
```

在调用这个脚本之前，需要给几个重要的变量赋值，包括LOCAL_MODULE_CLASS、LOCAL_SRC_FILES和LOCAL_DROIDDOC_OPTIONS等。

这些变量将作为droiddoc最终产生目标“文档”产物的基础——在我们这个例子中，“文档”意味着stub source。

我们只节选droiddoc.mk中与最终产物生成有关联的语句，以便大家可以更好地理解整个过程：

```
ifneq ($(strip $(LOCAL_DROIDDOC_USE_STANDARD_DOCLET)),true) ###dr
…
else ###标准doclet分支
$(full_target): $(full_src_files) $(full_java_lib_deps)
     @echo Docs javadoc: $(PRIVATE_OUT_DIR)
     @mkdir -p $(dir $@)
     $(call prepare-doc-source-list,$(PRIVATE_SRC_LIST_FILE),$(PR
               $(PRIVATE_SOURCE_INTERMEDIATES_DIR) $(PRIVATE_ADDI
     $(hide) ( \
          javadoc \ ###javadoc是生成doc的关键，其余工作都是围绕它展开的
                -encoding UTF-8 \
                $(PRIVATE_DROIDDOC_OPTIONS) \
                \@$(PRIVATE_SRC_LIST_FILE) \
                -J-Xmx1024m \
                -XDignore.symbol.file \
                $(PRIVATE_PROFILING_OPTIONS) \
                $(addprefix -classpath ,$(PRIVATE_CLASSPATH)) \
                $(addprefix -bootclasspath ,$(PRIVATE_BOOTCLASSPA
```

```
                -sourcepath $(PRIVATE_SOURCE_PATH)$(addprefix :,$
                -d $(PRIVATE_OUT_DIR) \
                -quiet \
        && touch -f $@ \
    ) || (rm -rf $(PRIVATE_OUT_DIR) $(PRIVATE_SRC_LIST_FILE); exi
endif
```

目前编译系统对doclet的实现方式进行了改进，从而出现了上述脚本中的if和else语句，即标准的doclet和doclava。不过这些并不是我们这里需要关心的重点，读者有兴趣的话可以自行查阅相关资料进行分析。

相信大家应该都听说过javadoc这个工具，它的基本用法如图3-20所示。

这样一来android.jar所需的stub就可以成功生成了，其他的中间件的处理过程也是类似的。一旦它们都处于Ready状态后，make sdk就可以将它们打包，并最终完成Android SDK的编译。

```
usage: javadoc [options] [packagenames] [sourcefiles] [@files]
-overview <file>          Read overview documentation from HTML file
-public                   Show only public classes and members
-protected                Show protected/public classes and members (default)
-package                  Show package/protected/public classes and members
-private                  Show all classes and members
-help                     Display command line options and exit
-doclet <class>           Generate output via alternate doclet
-docletpath <path>        Specify where to find doclet class files
-sourcepath <pathlist>    Specify where to find source files
-classpath <pathlist>     Specify where to find user class files
-exclude <pkglist>        Specify a list of packages to exclude
-subpackages <subpkglist> Specify subpackages to recursively load
-breakiterator            Compute 1st sentence with BreakIterator
-bootclasspath <pathlist> Override location of class files loaded
                          by the bootstrap class loader
-source <release>         Provide source compatibility with specified release
-extdirs <dirlist>        Override location of installed extensions
-verbose                  Output messages about what Javadoc is doing
-locale <name>            Locale to be used, e.g. en_US or en_US_WIN
-encoding <name>          Source file encoding name
-quiet                    Do not display status messages
-J<flag>                  Pass <flag> directly to the runtime system
-X                        Print a synopsis of nonstandard options

Provided by Standard doclet:
-d <directory>                    Destination directory for output files
-use                              Create class and package usage pages
-version                          Include @version paragraphs
-author                           Include @author paragraphs
-docfilessubdirs                  Recursively copy doc-file subdirectories
-splitindex                       Split index into one file per letter
-windowtitle <text>               Browser window title for the documenation
```

▲图3-20　javadoc界面

3.5 Android系统GDB调试

GDB是GNU Project Debugger的缩写，它也是很多开源软件的调试利器。对于Android这样一个庞大的系统，难免会在开发过程中遇到一些“难缠”的问题，这其中一个非常重要的解决办法就是通过GDB进行调试，因而我们觉得有必要向大家介绍一下GDB工具在Android系统中的典型用法。

实际上Android编译系统也已经为开发者使用GDB做了一些便利的工作，如/build/envsetup.sh：

```
function gdbclient()
{
   local OUT_ROOT=$(get_abs_build_var PRODUCT_OUT) ##得到out目录
   local OUT_SYMBOLS=$(get_abs_build_var TARGET_OUT_UNSTRIPPED)
   local OUT_SO_SYMBOLS=$(get_abs_build_var TARGET_OUT_SHARED_LIB
   local OUT_VENDOR_SO_SYMBOLS=$(get_abs_build_var TARGET_OUT_VEN
_UNSTRIPPED)
   local OUT_EXE_SYMBOLS=$(get_symbols_directory)
##得到Symbols目录，这是GDB将目标对象与源文件进行对应的关键

   local PREBUILTS=$(get_abs_build_var ANDROID_PREBUILTS)
    ##Prebuilts目录下有很多GDB相关的工具
   local ARCH=$(get_build_var TARGET_ARCH) ##ARCH决定了需要使用哪一个
   local GDB

   case "$ARCH" in
       arm) GDB=arm-linux-androideabi-gdb;;
       arm64) GDB=arm-linux-androideabi-gdb; GDB64=aarch64-linux-
       mips|mips64) GDB=mips64el-linux-android-gdb;;
       x86) GDB=x86_64-linux-android-gdb;;
       x86_64) GDB=x86_64-linux-android-gdb;;
       *) echo "Unknown arch $ARCH"; return 1;;
   esac ##通过ARCH来选定GDB客户端，通常这些客户端工具保存在prebuilts目录

   if [ "$OUT_ROOT" -a "$PREBUILTS" ]; then
       local EXE="$1" ###EXE代表的是需要被调试的应用程序
       if [ "$EXE" ] ; then
           EXE=$1
           if [[ $EXE =~ ^[^/].* ]] ; then
               EXE="system/bin/"$EXE
           fi
       else
```

```
        EXE="app_process" ##默认情况下调试app_process
    fi

    local PORT="$2" ##端口号，必须与gdbserver保持一致
    if [ "$PORT" ] ; then
        PORT=$2
    else
        PORT=":5039" ##端口号默认为5039
    fi

    local PID="$3" ##PID表示被调试对象的进程号，也可以只提供进程名，后
    if [ "$PID" ] ; then
        if [[ ! "$PID" =~ ^[0-9]+$ ]] ; then
            PID=`pid $3`
            if [[ ! "$PID" =~ ^[0-9]+$ ]] ; then
                PID='adb shell ps | \grep $3 | \grep -v ":" |
                if [[ ! "$PID" =~ ^[0-9]+$ ]]
                then
                    echo "Couldn't resolve '$3' to single PID"
                    return 1
                else
                    echo ""
                    echo "WARNING: multiple processes matching
                using root process"
                    echo ""
                fi
            fi
        fi
        adb forward "tcp$PORT" "tcp$PORT" ##端口映射
        local USE64BIT="$(is64bit $PID)"
        adb shell gdbserver$USE64BIT $PORT --attach $PID & ##g
        sleep 2
    else
            echo ""
            echo "If you haven't done so already, do this firs
            echo "    gdbserver $PORT /system/bin/$EXE"
                echo " or"
            echo "    gdbserver $PORT --attach <PID>"
            echo ""
    fi

    OUT_SO_SYMBOLS=$OUT_SO_SYMBOLS$USE64BIT
    OUT_VENDOR_SO_SYMBOLS=$OUT_VENDOR_SO_SYMBOLS$USE64BIT
    echo >|"$OUT_ROOT/gdbclient.cmds" "set solib-absolute-pref
    echo >>"$OUT_ROOT/gdbclient.cmds" "set solib-search-path $
SYMBOLS/hw:$OUT_SO_SYMBOLS/ssl/engines:$OUT_SO_SYMBOLS/drm:$OUT_S
    echo >>"$OUT_ROOT/gdbclient.cmds" "source $ANDROID_BUILD_T
```

```
scripts/gdb/dalvik.gdb"
       echo >>"$OUT_ROOT/gdbclient.cmds" "target remote $PORT"
       ###将GDB需要的一些参数写入脚本文件中
       …

       local WHICH_GDB=
       # 64-bit exe found
       if [ "$USE64BIT" != "" ] ; then
           WHICH_GDB=$ANDROID_TOOLCHAIN/$GDB64
       # 32-bit exe / 32-bit platform
       elif [ "$(get_build_var TARGET_2ND_ARCH)" = "" ]; then
           WHICH_GDB=$ANDROID_TOOLCHAIN/$GDB
       # 32-bit exe / 64-bit platform
       else
           WHICH_GDB=$ANDROID_TOOLCHAIN_2ND_ARCH/$GDB
       fi
       ###WHICH_GDB是GDB客户端的绝对路径

       gdbwrapper $WHICH_GDB "$OUT_ROOT/gdbclient.cmds" "$OUT_EXE
  else
       echo "Unable to determine build system output dir."
   fi

}
```

综合上面的分析，可以发现gdbclient函数的实现是围绕两个方面展开的。为了让大家可以更快地理解使用gdb的整个过程，下面我们以调试surfaceflinger为例来讲解。

（1）gdb server

这是运行在Android设备端（量产的设备中很可能会被移除）的一个监听服务，通常路径为/system/bin/gdbserver。

Gdbserver有两个使用场景。

- attach

如果被调试的程序已经在运行，那么我们就需要“attach”上它。在这种情况下，我们最好能先通过ps命令来获取到被测试对象的PID。比如attach surfaceflinger，那么先利用adb shell ps来找到surfaceflinger的进程号，接着在adb shell中使用如下命令：

```
gdbserver --attach :5039 [PID]
```

其中“:5039”表示gdbserver将在localhost的5039端口进行监听。

- 启动被调试对象

上述的attach用于调试已经在运行的被测对象，而如果希望从头开始调试目标对象，那么可以采用这个场景。以surfaceflinger为例，以下命令可以启动一个新的surfaceflinger程序来进行调试：

```
gdbserver :5039 /system/bin/surfaceflinger
```

（2）gdb client

当gdbserver处于监听状态下时，我们就可以启动gdb客户端了。

首先需要切换到Android工程的根目录下，然后执行：

```
source /build/envsetup.sh
```

这个步骤是为了保证我们可以正常使用各种函数。

接下来就可以启动gdbclient了，下面是调试surfaceflinger所用的命令：

```
gdbclient  surfaceflinger  :5039  [PID]
```

也就是对应前面看到的$1,$2,$3各变量。其中“:5039”和[PID]都需要与gdbserver中的保持一致，才能保证正常连接。

一切顺利的话，此时gdb client和gdb server就已经建立连接了。我们可以通过gdb提供的一系列丰富的命令进行各种调试工作。下面是gdb提供的官方指导文档，供大家参考查询：

https://sourceware.org/gdb/download/onlinedocs/gdb/index.ht

第2篇
Android原理篇

第4章 操作系统基础

第5章 Android进程/线程和程序内存优化

第6章 进程间通信——Binder

第7章 Android启动过程

第8章 管理Activity和组件运行状态的系统进程——ActivityManagerService（AMS）

第9章 GUI系统——SurfaceFlinger

第10章 GUI系统之“窗口管理员”——WMS

第11章 让你的界面炫彩起来的GUI 系统——View体系

第12章 “问渠哪得清如许，为有源头活水来”——InputManager Service与输入事件

第13章 应用不再同质化—音频系统

第4章
操作系统基础

4.1 计算机体系结构（Computer Architecture）

硬件是软件的基石，所有的软件功能最终都是由硬件来实现的。无论是复杂的数学运算、图像处理，还是简单的文本显示、编辑，其软件实现首先都是架构在硬件之上，然后由此逐层不断抽象堆叠而起的。因此，要彻底理解软件，没有一定的硬件基础是不行的。

当然，硬件是一个笼统而宽泛的概念。我们不能强制要求软件工程师都能理解每个电子元器件的电气特性，或者先学习电路排版作图然后编写程序。这就像汽车与驾驶员的关系：要求驾驶员必须透彻理解发动机的原理和内部构造才能开车显然是行不通的，但能了解发动机工作机理的驾驶员就一定能在开车的过程中受益匪浅。

计算机体系结构作为一门学科，是软件和硬件的抽象体，也是所有开发者的入门课。它对于我们理解程序设计，特别是操作系统原理，有十分重要的意义。

4.1.1 冯·诺依曼结构

冯·诺依曼（Von Neumann）是20世纪公认的最伟大的科学家之一。他的贡献领域相当广泛，Von Neumann architecture就是其中之一。

冯·诺依曼结构（Von Neumann Architecture）又被称为“冯诺依曼模型”或者“普林斯顿结构”，起源于Neumann在1945年发表的一篇

关于EDVAC（Electronic Discrete variable Automatic Computer，电子离散变量自动计算机）的论文。

就是在这篇文章中，他提出了两个对计算机领域产生了深远影响的观点。

- 采用二进制，抛弃十进制

根据电子元件的工作特点，冯诺依曼提出了使用二进制的设想。他认为这将极大简化计算机设备的逻辑线路，后来的事实也验证了他的这一推断。

- 程序存储（stored-program）

除了二进制，他还建议计算机能实现程序存储和程序控制。具体而言，程序指令和数据都存放在同一内存储器中，因此它们的宽度是一样的。不过程序与数据共享同一总线在一定程度上也成了制约冯诺依曼机器的瓶颈。

冯诺依曼结构中包含了运算器、控制器、输入输出设备等元素，其关系如图4-1所示。

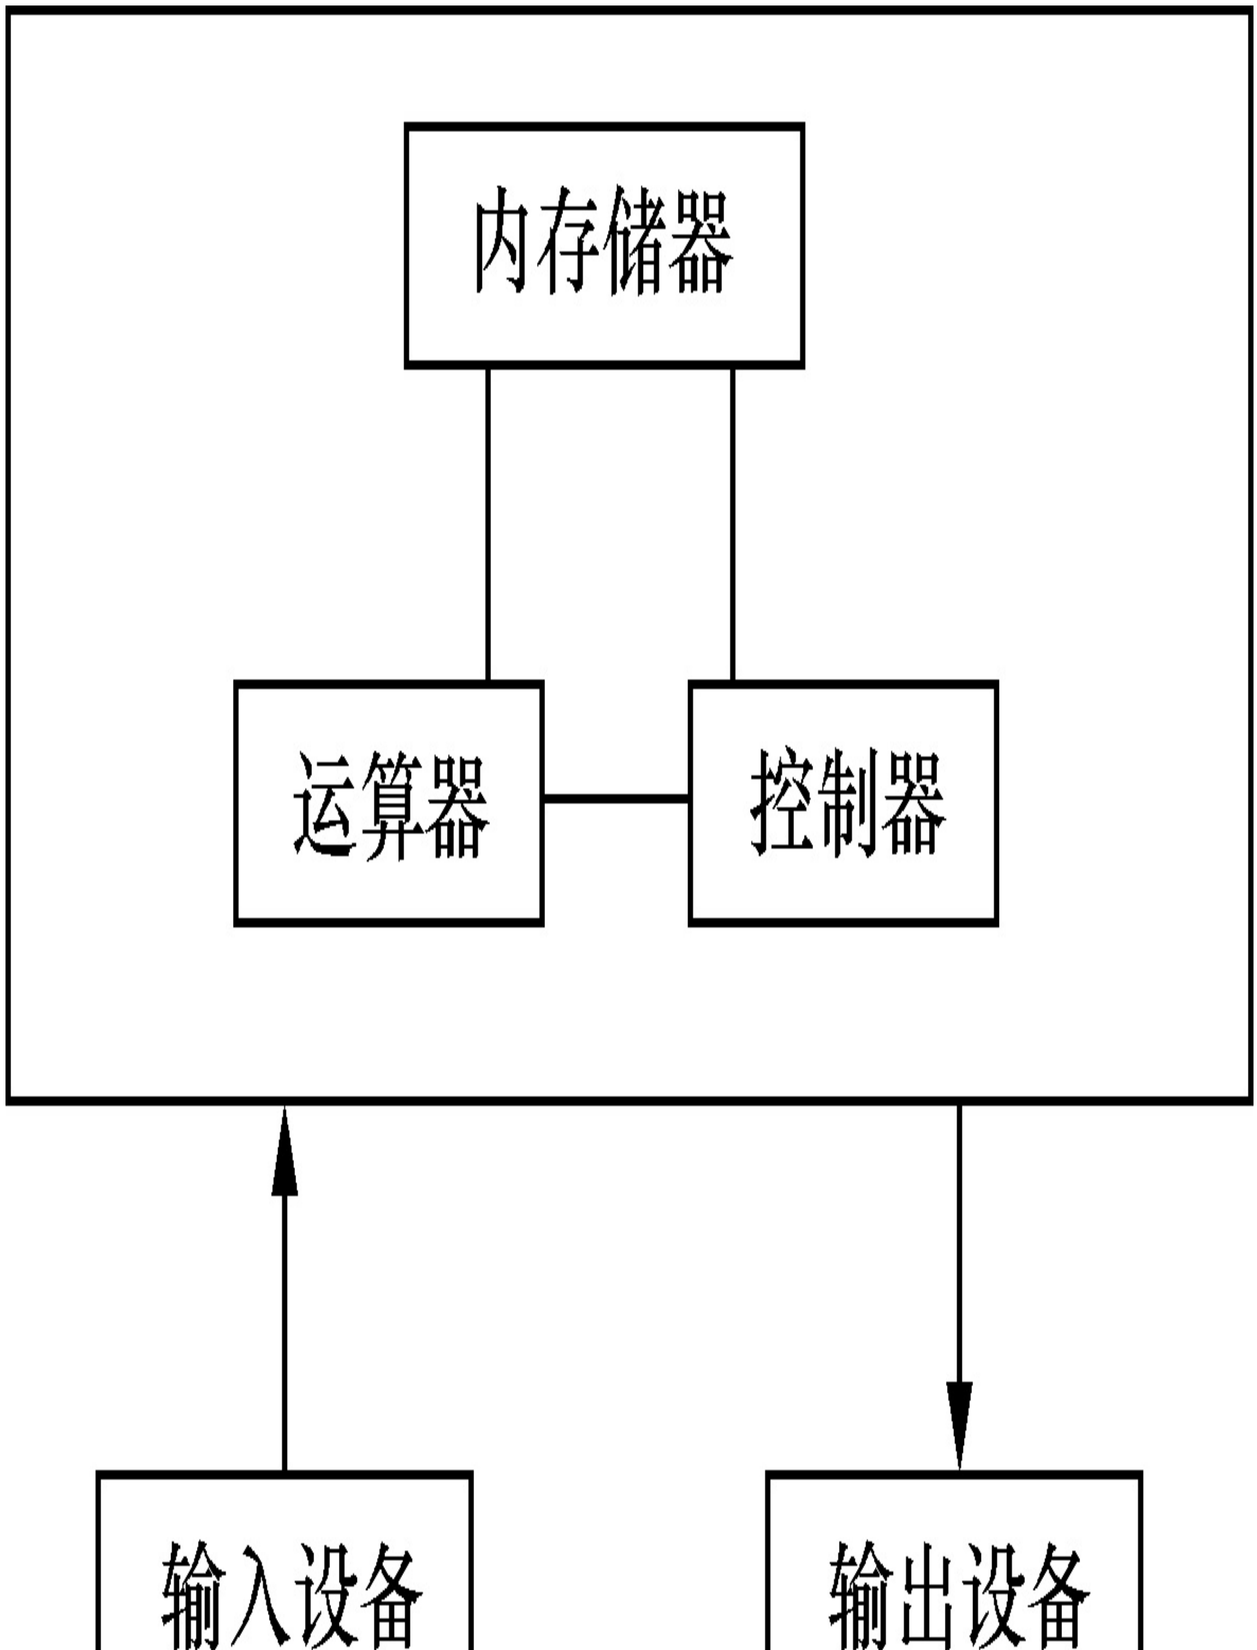
内存储器
运算器
控制器
输入设备
输出设备

▲图4-1　冯诺依曼结构

从早期的EDVAC到现代很多最先进的计算机，都采用了冯诺依曼结构，可见其影响之深。

4.1.2　哈佛结构

值得一提的是，哈佛结构（Harvard Architecture）并不是作为冯诺依曼结构的对立面出现的；相反，它们都属于stored-program类型体系。区别就在于前者的指令与数据并不保存在同一个存储器中，即哈佛结构是对冯诺依曼结构的改进与完善，其关系如图4-2所示。

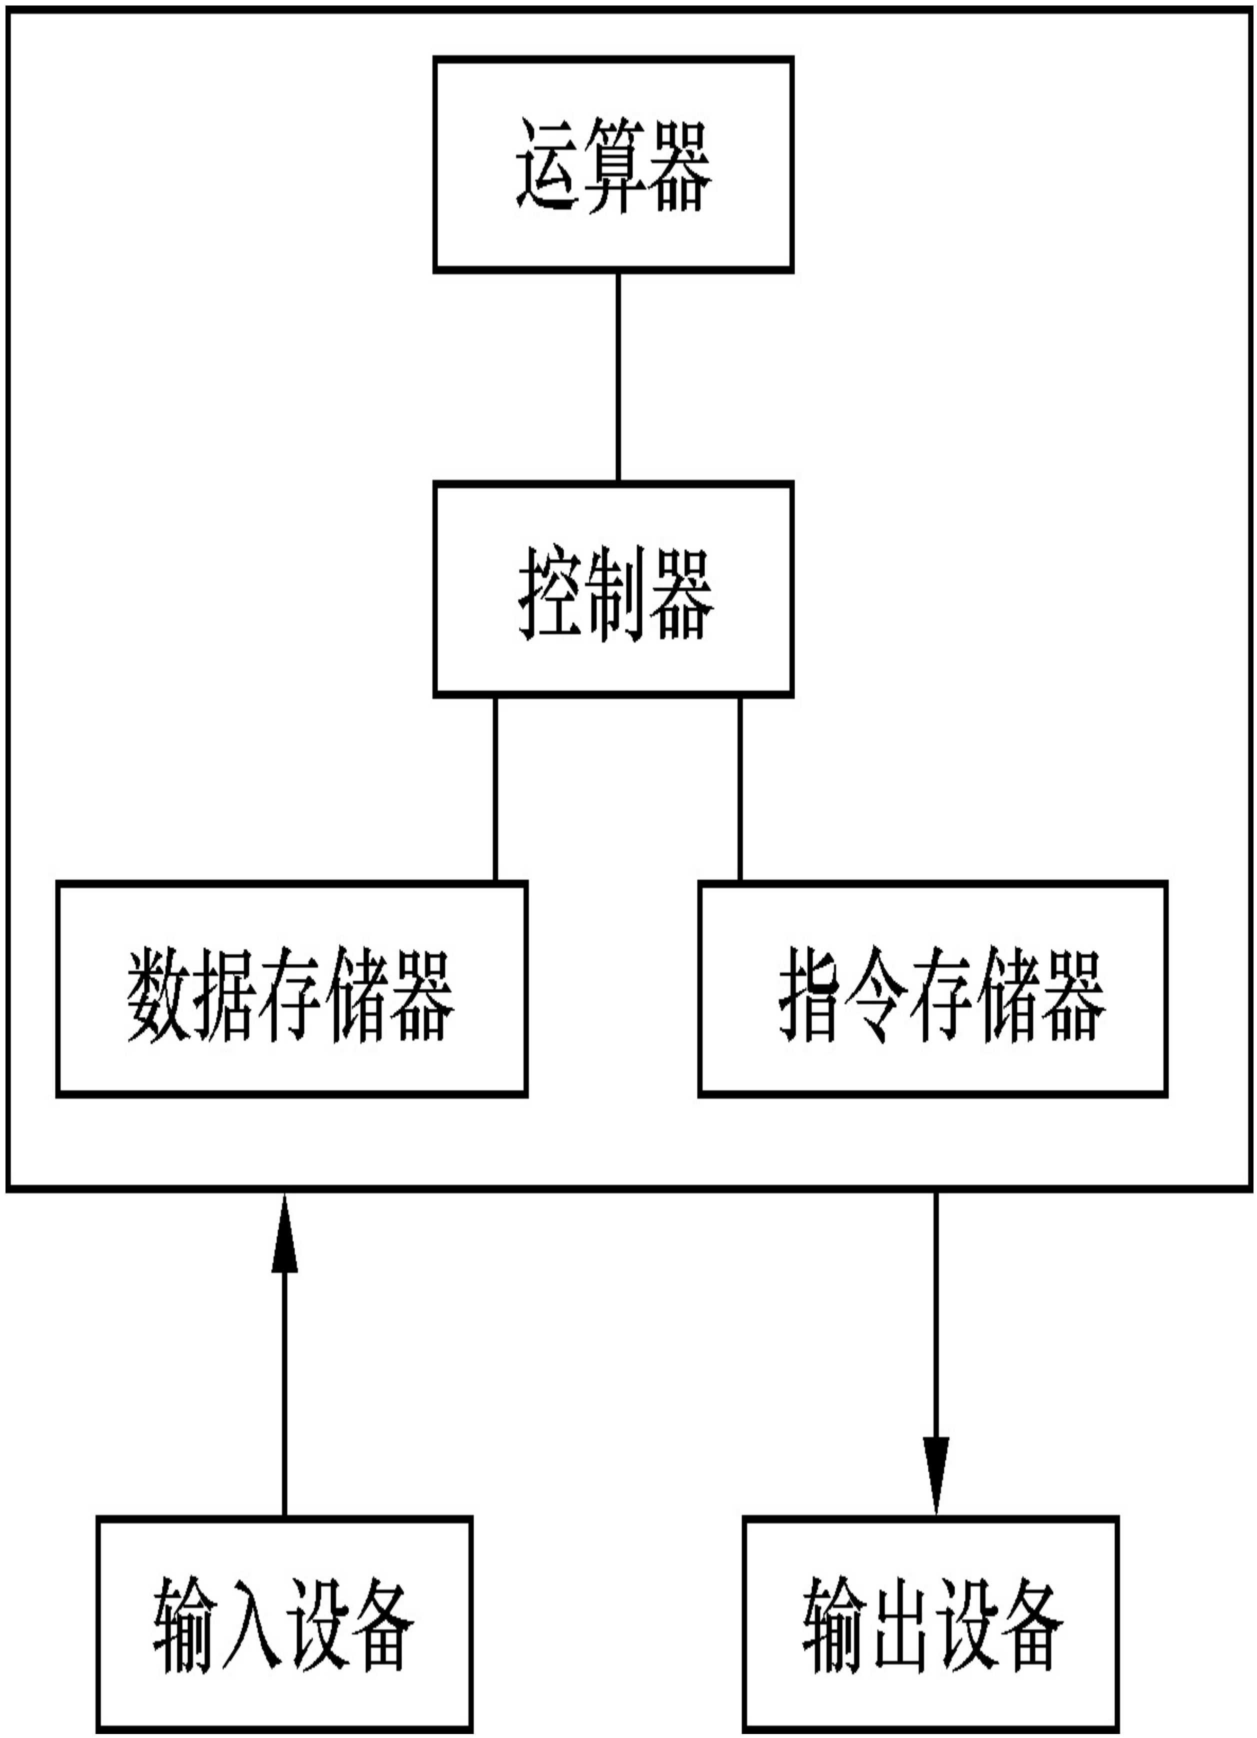
运算器
控制器
数据存储器
指令存储器
输入设备
输出设备

▲图4-2　哈佛结构

这意味着：

- 指令与数据可以有不同的数据宽度；
- 执行速度更快。

由于取指令和数据无法同步进行，冯诺依曼结构的执行速率并不占优势。而采用哈佛结构的计算机由于指令和数据的单独存储，可以在执行操作的同时预读下一条指令，所以在一定程度上可以提高其吞吐量。

哈佛结构的缺点在于构架复杂且需要两个存储器，因而通常会被运用在对速度有特殊需求且成本预算相对较高的场合。目前市面上采用哈佛结构的芯片包括ARM公司的ARM9、ARM11，以及ATMEL公司的AVR系列等。

不论是何种结构，它们所包含的基本元素都是不变的，即：

- CPU（中央处理器）；
- 内存储器；
- 输入设备；
- 输出设备。

其中输入和输出设备一般会统称为I/O设备（外存储器实际上也归于这一类）。因而，最后可以把计算机结构简化为：

- 中央处理器；
- 内存储器；
- I/O设备。

无论是哪款操作系统（如Windows、Linux、Android等），都是建构在计算机体系结构之上的。脱离了这一点，操作系统就会变成“无源之水”。

本书接下来所有章节的内容都是基于这一理解展开的，希望读者也能以体系结构为线索贯穿整个Android系统的学习。

4.2　什么是操作系统

其实有很多概念我们在平常的工作学习中都会经常碰到，如操作系统、体系结构等。然而真正需要对它们进行精确定义时，大部分人却可能会有一种无所适从、似懂非懂的感觉。这说明我们以前对它们“只知其然，而不知其所以然”——仅仅是在有意或者无意的情况下泛泛地了解一下，并没有尝试从本质上去深层次地挖掘。

那么，到底什么是操作系统呢？

发展到今天，市面上可供用户选择的操作系统已经具备相当的数量；而且出于版权及成本等因素的考虑，针对不同领域的操作系统如“雨后春笋”般还在不断涌现。

这些操作系统可以按照不同的角度进行分类，如表4-1所示。

表4-1　　操作系统分类

分 类 角 度	示　　例
应用领域	● 桌面型操作系统 ● 服务器型操作系统 ● 嵌入式操作系统
支持的用户数	● 单用户，如DOS ● 多用户，如Windows、UNIX
实时性	● 实时操作系统，如RTOS、VRTX ● 分时系统，如UNIX、Mac OS
	● 8 bit ● 16 bit

指令长度	• 32 bit • 64 bit
分布性（distributed）	• 分布式操作系统 • 网络操作系统
源码开放程度	• 开源系统，如Linux、Android • 闭源系统，如Windows、MAC OS
UNIX系列	• UNIX-like，如Minix、UNIX、Xinu • Non-UNIX-like，如Windows
与POSIX的兼容性	• 兼容POSIX，如Linux • 不兼容或不完全兼容POSIX

面对如此众多的操作系统，我们希望可以提取出它们的共性。

人们常说“艺术来源于生活，却又高于生活”。同样的，我们也可以从工作、生活中的相关“片断”来理解操作系统。比如：

- 操作系统对硬件设备本身是有要求的

比如市面上Android系统面对的多是手机、平板这些嵌入式领域，以ARM芯片为主；而Windows XP、Windows 7/Windows 8系列则基本应用在PC市场。当然，你可能也会从新闻上看到某些“牛人”将Android“移植”（而不是直接使用）到了PC上。

这些线索告诉我们，操作系统必须针对“硬件”来研发。

- 同一款操作系统可以安装在不同型号的机器上

比如采用Android系统的手机、平板数量众多。同样的，Windows系

列操作系统也可以安装在不同品牌配置的PC上。由此我们可以做出推断，操作系统是针对某些“硬件架构”的，如ARM、x86等。

- 操作系统提供可用的人机交互界面

登录Windows系统后，我们可以在不安装任何程序的情况下浏览硬盘中的文件；原生态的Android系统中用户也可以直接进行短信编辑、通话等操作，这都得益于操作系统预装的各种人机交互程序。

- 操作系统支持用户编写和安装程序

这是操作系统真正的魅力所在，也是OS生态圈能得以循环的关键。在Windows环境中编写任意类型的应用程序（游戏、文本编辑工具、浏览器等），几乎都可以调用Microsoft提供的各种现成的API；在Android中开发APK应用，同样是基于SDK或者NDK来完成的，而不是直接与底层硬件打交道。

基于上面的几点分析，我们可以大致得出操作系统的共同特征，如图4-3所示。

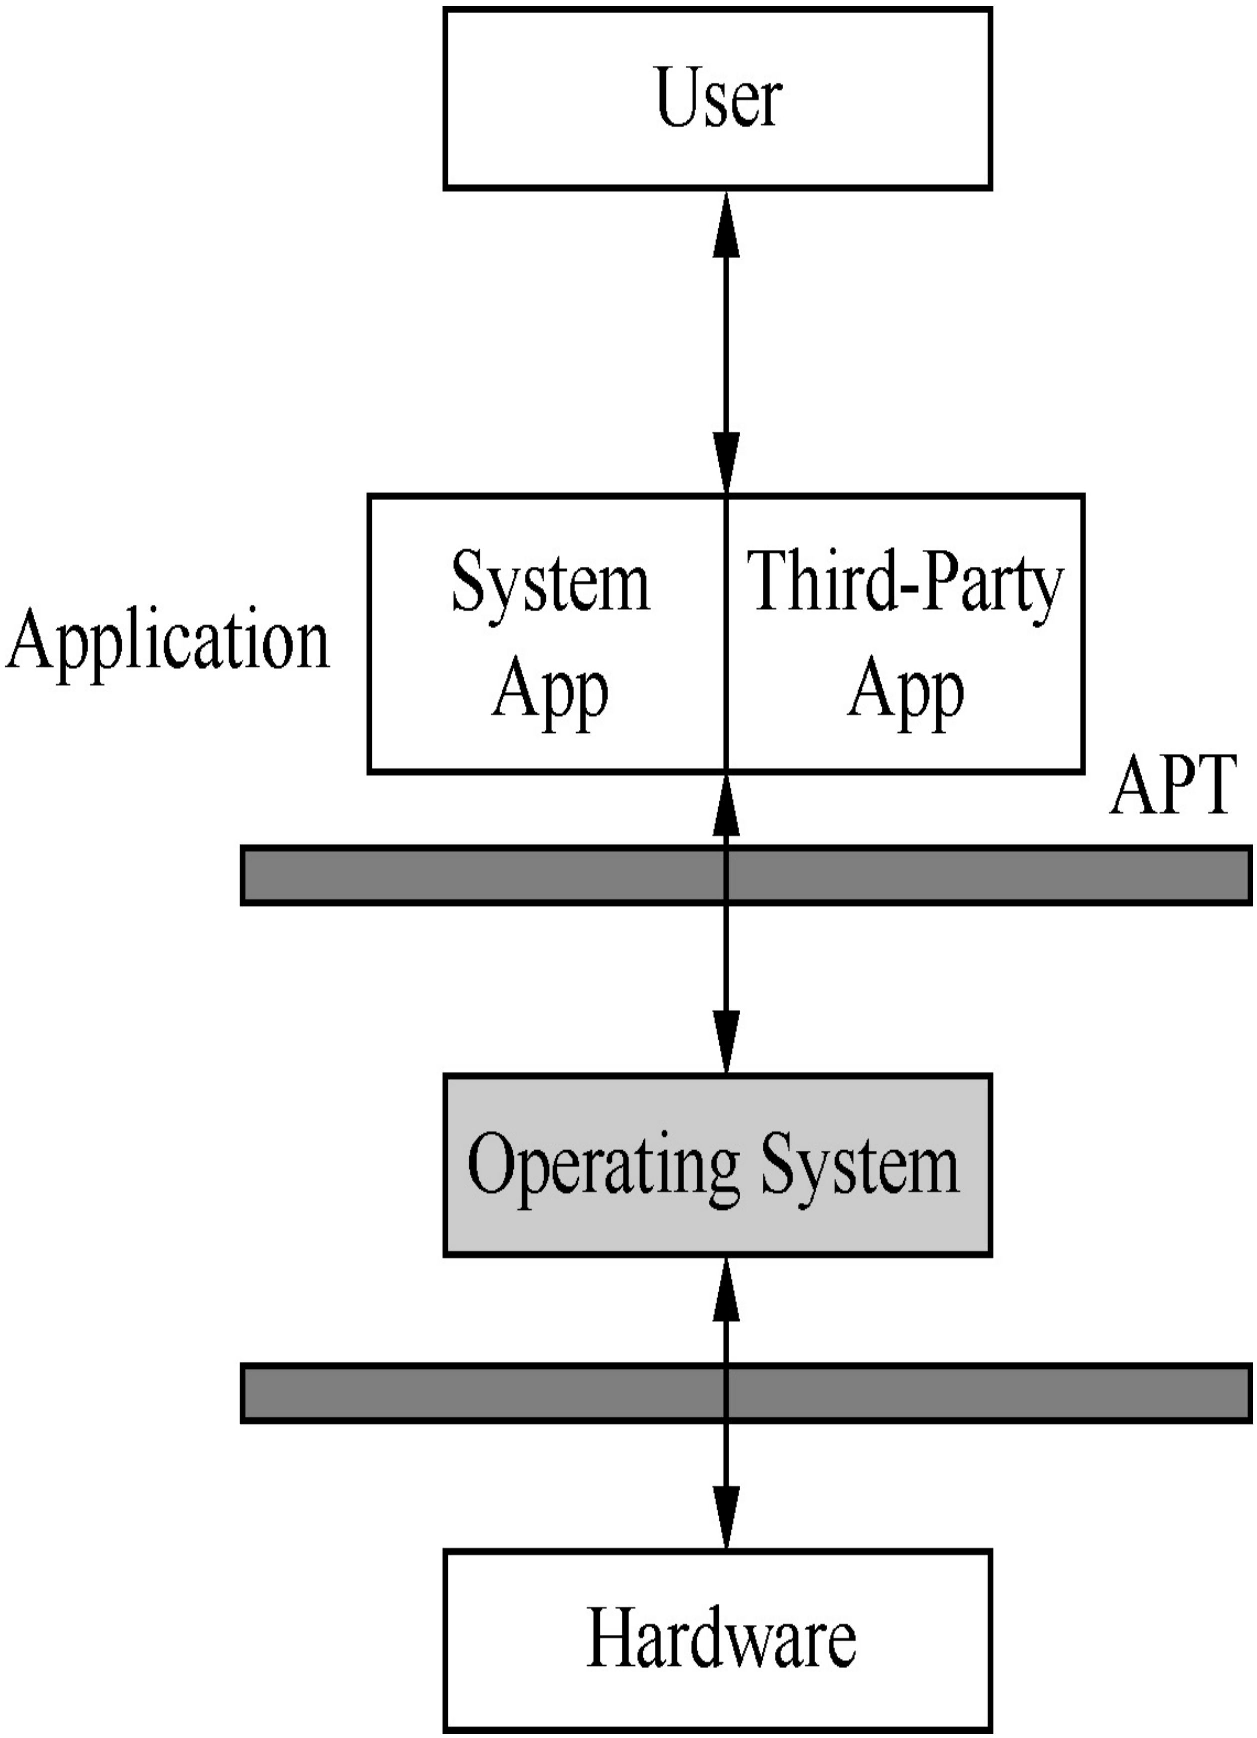
User
Application
System
App
Third-Party
App
APT
Operating System
Hardware

▲图4-3 操作系统的抽象特征

操作系统“肩负”两大重任。

- 面向下层

管理硬件。这里的硬件是笼统的概念，它包含了CPU、内存、Flash、各种I/O设备等系统中所有硬件组成元素。

- 面向上层

一方面，操作系统需要为用户提供可用的人机交互界面；另一方面，它还负责为第三方程序的研发提供便捷、可靠、高效的API（Application Programming Interface）。这样上层应用的设计实现就可以不用直接面向硬件，从而大大缩短了应用开发的时间。

由此，我们可以给操作系统下一个简洁的定义。

计算机操作系统是负责管理系统硬件，并为上层应用提供稳定编程接口和人机交互界面的软件集合。

这一概念虽然浅显，却是我们在学习操作系统（而不仅仅是Android）时的指南针。因为它指出了操作系统最核心的工作，即硬件管理与抽象。任何类型的操作系统都逃不出这个范畴。

操作系统作为“硬件大管家”，任重而道远。特别是随着硬件的不断发展，会有越来越多的“成员”加入这个“大家庭”中。所以一款成功的操作系统，往往是数以千计的工程师花费几年、日夜奋战的结晶。而Android系统的诞生年头还很短，何以能风靡各大领域呢？

其中一个非常重要的原因，就是Android系统是基于Linux Kernel的。

Google员工Patrick Brady，曾在2008年的I/O大会上做过一篇名为《Android Anatomy and Physiology》的主题演讲。其中提到过Android采用Linux内核的原因（Why Linux Kernel）。摘录如下：

- Great memory and process management;
- Permissions-based security model;
- Proven driver model;
- Support for shared libraries;
- It’s already open source!

从中可以看出，操作系统的难点包括了进程和内存管理、硬件驱动的支持等。而这些正是Linux的长处所在。更为可贵的是，内核本身也是开源项目——于是Android与Linux“一拍即合”，遂成一方霸业。

虽然Android系统的底层完全基于Linux Kernel来实现，但并不代表它可以彻底“撒手不管”；相反，对于进程/线程和内存的管理，Android本身也做了不少努力。接下来的几个小节，我们会先向读者讲解内核的进程/线程相关基础知识，然后兼顾Android在这上面所做的“特色”工作。

4.3　进程间通信的经典实现

我们知道，操作系统中的各个进程通常运行于独立的内存空间中，并且有严格的机制来防止进程间的非法访问。但是，这并不代表进程与进程间不允许互相通信；相反，进程间通信是操作系统中一个重要的概念，应用非常广泛。举个实用的例子，我们常用的Windows操作系统中的剪贴板，就可以让用户轻松地从一个程序中复制信息到另一个毫无关联的程序中。

广义地讲，进程间通信（Inter-process communication，IPC）是指运行在不同进程（不论是否在同一台机器）中的若干线程间的数据交换，具体如图4-4所示。

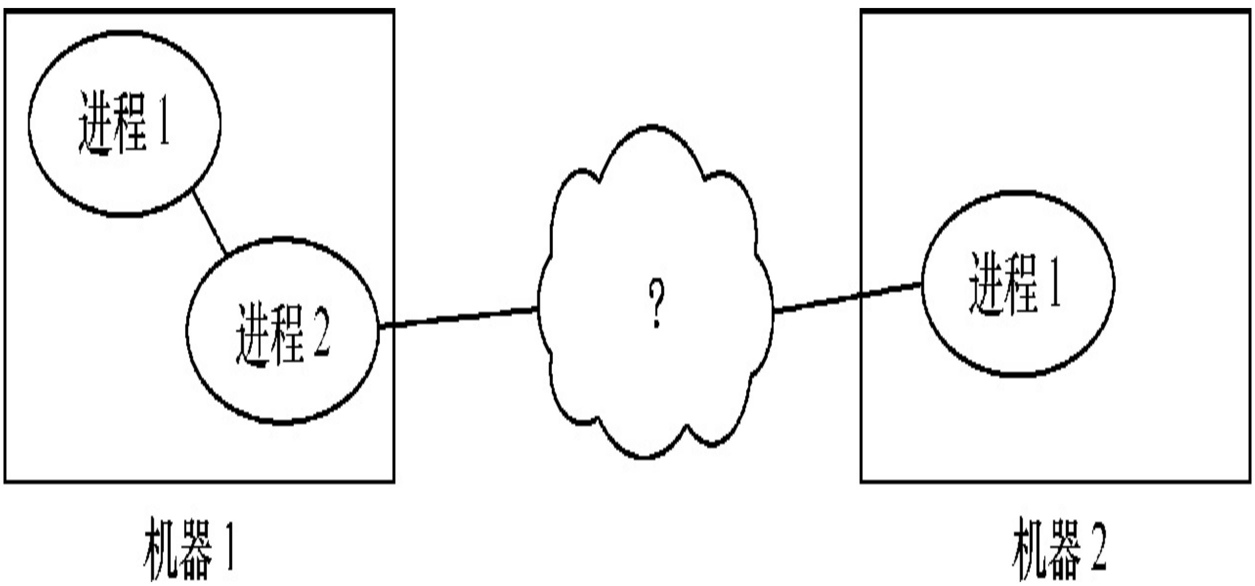

▲图4-4　IPC释义

从这个定义可以看到：

- IPC中参与通信的进程既可运行在同一台机器上，也允许它们存在于各自的设备环境中（RPC）。如果进程是跨机器运行的，则通常由网络连接在一起，这无疑给进程间通信的实现增加了难度。后续小节有专门针对这种情况的讨论，如图4-5所示。

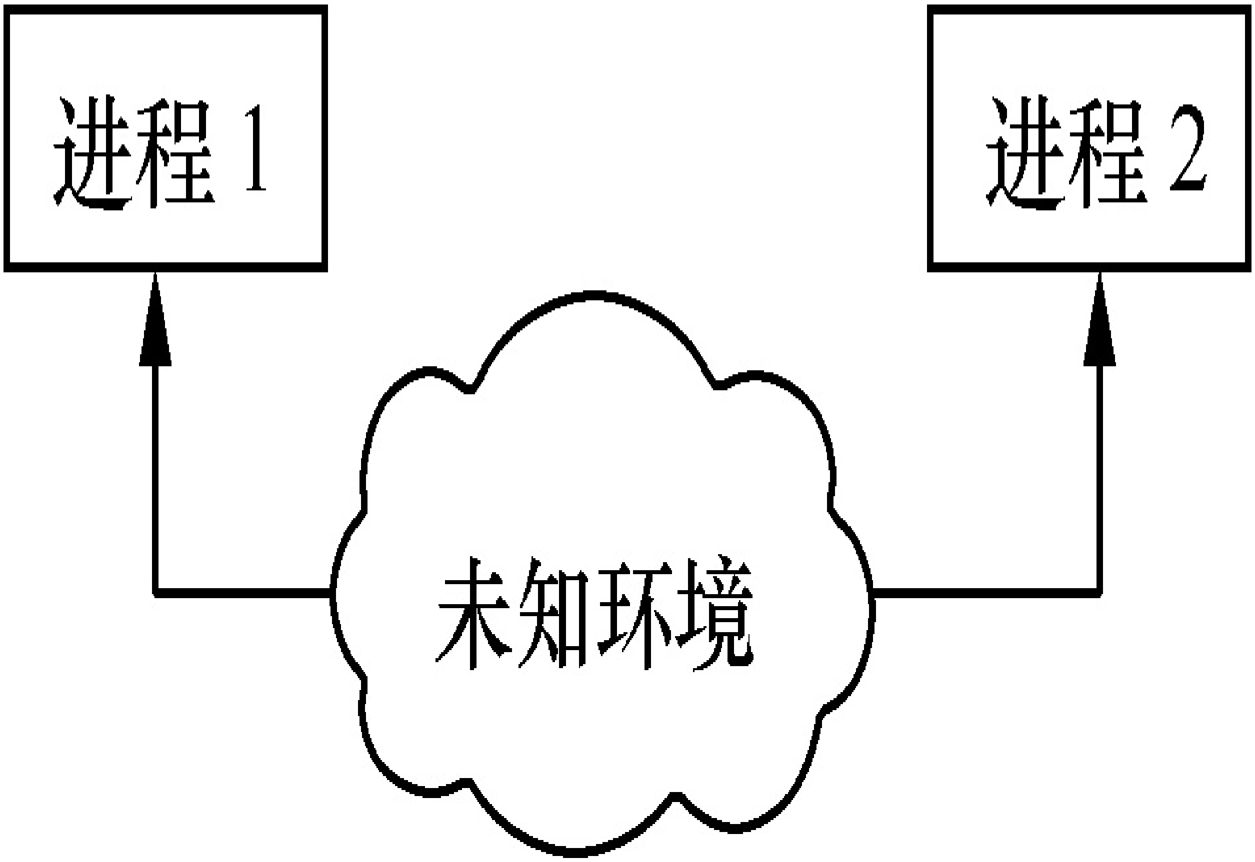

▲图4-5　进程间通信的未知因素

- 实现方式多种多样。原则上，任何跨进程的数据交换都可以称为进程间通信。除了传统意义上的消息传递、管道等，还可以使用一些简单的方法来实现对性能要求不高的进程通信。比如：

- 文件共享

比如两个进程间约定以磁盘上的某个文件作为信息交互的媒介。在这种情况下，要特别注意不同进程访问共享文件时的同步问题。

- 操作系统提供的公共信息机制

比如Windows上的注册表对于所有进程来说都是可以访问的，因而在特定情况下也能作为进程间信息交换的平台。

虽然各操作系统所采用的进程间通信机制可以说五花八门，但以下将要讨论的几种却因其高效、稳定等优点而几乎被广泛应用于所有操作

系统中。

4.3.1 共享内存（Shared Memory）

共享内存是一种常用的进程间通信机制。由于两个进程可以直接共享访问同一块内存区域，减少了数据的复制操作，因而速度上的优势比较明显。一般情况下，实现内存共享的步骤如图4-6所示。

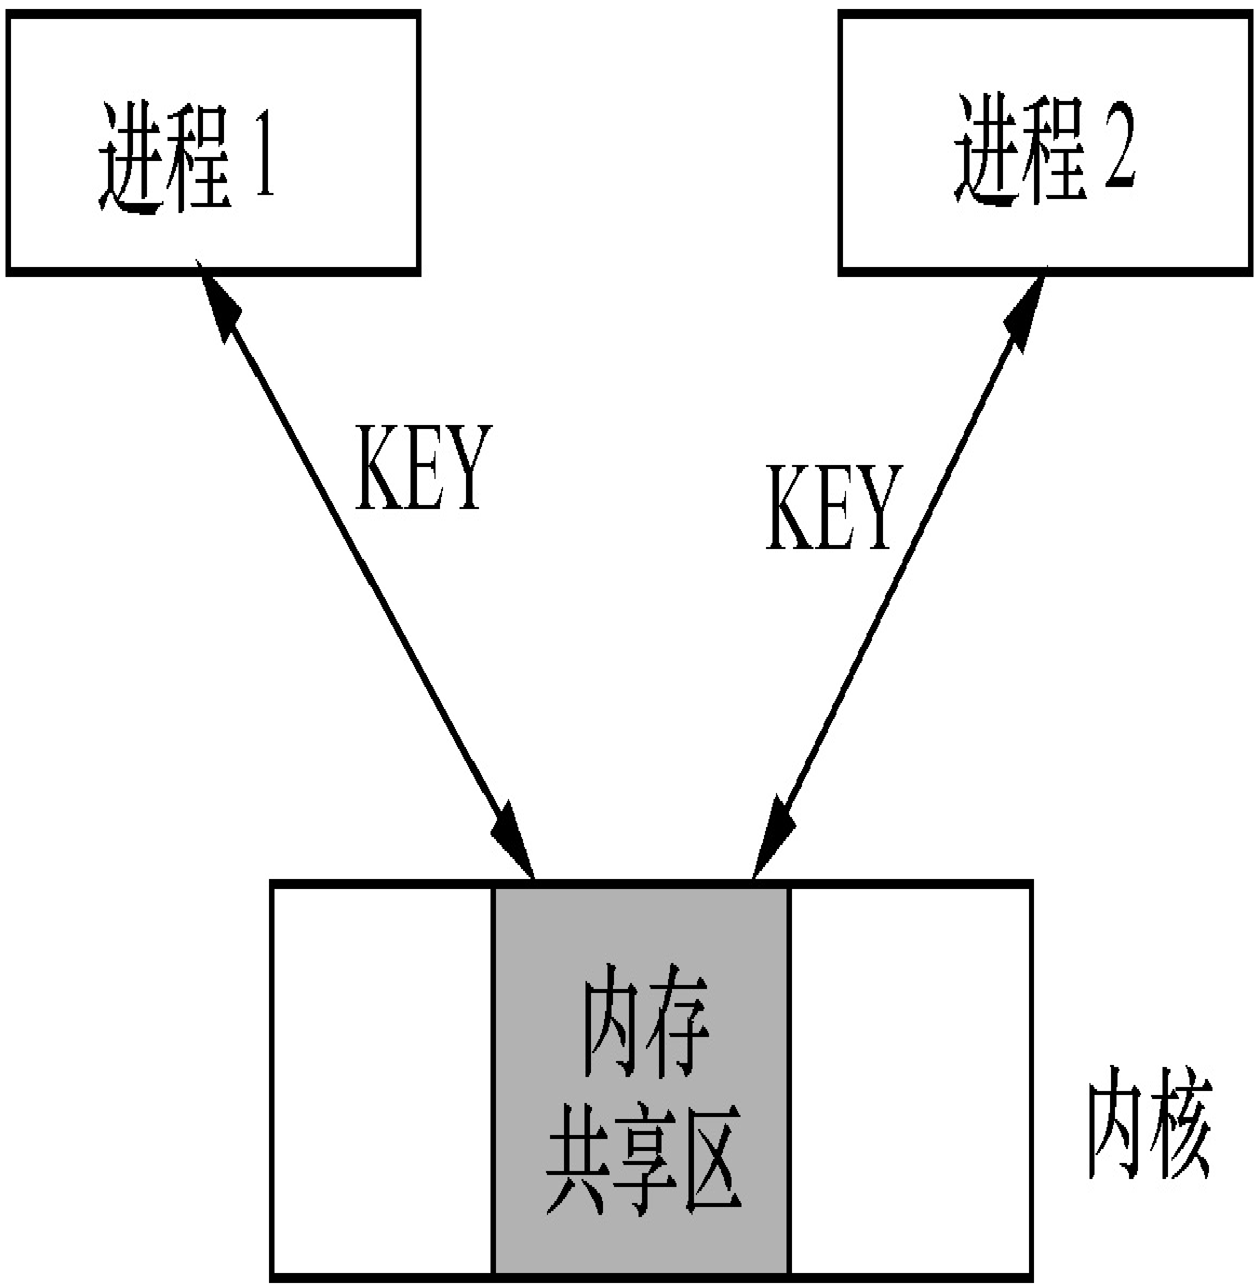

▲图4-6　共享内存机制

Step1. 创建内存共享区

图4-6中进程1首先通过操作系统提供的API从内存中申请一块共享区域——比如在Linux环境中可以通过shmget函数来实现（参见后面的表格说明）。生成的共享内存块将与某个特定的key（即shmget的第一个参数）进行绑定。

Step2. 映射内存共享区

成功创建了内存共享区后，我们需要将它映射到进程1的空间中才能进一步操作。在Linux环境下，这一步可以通过shmat来实现。

Step3.访问内存共享区

进程1已经创建了内存共享区，那么进程2如何访问到它呢？没错，就是利用第一步中的key。具体而言，进程2只要通过shmget，并传入同一个key值即可。然后进程2执行shmat，将这块内存映射到它的空间中。

Step4. 进程间通信

共享内存的各个进程实现了内存映射后，便可以利用该区域进行信息交换。由于内存共享本身并没有同步的机制，所以参与通信的诸进程需要自己协商处理。

Step5. 撤销内存映射区

完成了进程间通信后，各个进程都需要撤销之前的映射操作。在Linux中，这一步可以通过shmdt来实现。

Step6. 删除内存共享区

最后必须删除共享区域，以便回收内存。在Linux环境中，可以通过shctl函数来实现。

表4-2详细讲解了Linux中内存共享机制的各函数实现。

表4-2　内存共享机制相关函数说明

<table>
<tr><th rowspan="2">函 数 原 型</th><th rowspan="2">头 文 件</th><th colspan="3">参 数 说 明</th></tr>
<tr><th>参 数 名</th><th>方 向</th><th>说 明</th></tr>
<tr><td rowspan="4">int shmget(key_t key, size_t size, int shmflg);</td><td rowspan="4"><sys/ipc.h>
<sys/shm.h></td><td>key</td><td>IN</td><td>两种情况下系统会为shmget创建一块新的内存共享区：
（1）key值为IPC_PRIVATE
（2）key不为IPC_PRIVATE，但shmflg指定了IPC_CREAT标志</td></tr>
<tr><td>size</td><td>IN</td><td>申请的共享区的大小，以字节为单位。但要注意，Linux下分配的内存大小都是页的整数倍</td></tr>
<tr><td>shmflg</td><td>IN</td><td>IPC_CREAT：申请新建区域
IPC_EXCL：和IPC_CREAT共同使用。如果指定的区域已经存在，则返回错误
mode_flags：参照open函数中的mode参数
SHM_HUGETLB：使用“huge pages”机制来申请（Linux 2.6后版本有效）
SHM_NORESERVE：此区域不保留swap空间</td></tr>
<tr><td>返回值</td><td>OUT</td><td>内存共享区域的id值，用于唯一识别该</td></tr>
</table>

				区域
char *shmat(int shmid , void *shmaddr , int shmflag);	<sys/types.h> <sys/ipc.h> <sys/shm.h>	shmid	IN	共享内存区的id值，是由shmget成功执行后返回的
		shmaddr	IN	将共享内存区映射到指定地址。可以为0，此时系统将自动分配地址
		shmflag	IN	同shmget
		返回值	OUT	成功执行后，返回该内存区的起始地址
int shmdt(char *shmaddr);	<sys/types.h> <sys/ipc.h> <sys/shm.h>	shmaddr	IN	同shmat
		返回值	OUT	0表示成功，否则表示失败
int shmctl(int shmid , int cmd , struct shmid_ds *buf);	<sys/shm.h>	shmid	IN	同shmget的返回值
		cmd	IN	控制命令，可选值如下： IPC_STAT：状态查询，结果存入buf中 IPC_SET：在权限允许的情况下，将共享内存状态更新为buf中的数据 IPC_RMID：删除共享内存段
		buf	IN/OUT	如上所述
		返回值	OUT	0表示成功，否则表示失败

4.3.2 管道（Pipe）

管道也是操作系统中常见的一种进程间通信方式，它适用于所有POSIX系统以及Windows系列产品。

Pipe这个词很形象地描述了通信双方的行为，即进程A与进程B。

- 分立管道的两边，进行数据的传输通信。
- 管道是单向的，意味着一个进程中如果既要“读”也要“写”的话，那么就得建立两根管道。这点很像水管的特性，通常水流只做正向或反向行进。
- 一根管道同时具有“读取”端（read end）和“写入”端（write end）。比如进程A从write end写入数据，那么进程B就可以从read end读取到数据。
- 管道有容量限制。即当pipe满时，写操作（write）将阻塞；反之，读操作（read）也会阻塞。2.6.11版本以前的Linux内核，管道的容量和page size是一致的，之后版本中改为65536字节。

在Linux环境中使用pipe的流程和一般的文件操作类似，下面给大家提供一个范例：

```
/*Linux中的管道示例*/
  #include <sys/wait.h>
  #include <stdio.h>
  #include <stdlib.h>
  #include <unistd.h>
  #include <string.h>

  int main(int argc, char *argv[])
  {
      int    pipe_fd[2];//管道的read end和write end
      pid_t child_pid;//子进程
      char   pipe_buf;//管道数据
      memset(pipe_fd, 0, sizeof(int)*2);//初始化

      if (pipe(pipe_fd) == -1) {/*通过pipe接口打开管道，pipe_fd
                                 表读、写端*/
          /*出错处理*/
```

```
            return -1;
        }

        child_pid= fork(); //fork一个子进程
        if (child_pid == -1) {
        /*出错处理*/
        return -1;
        }

        if (child_pid == 0) {   /*子进程中的操作*/
            close(pipe_fd[1]); /*关闭写端，因为子进程负责读取*/
            while (read(pipe_fd[0], &pipe_buf, 1) > 0)/*从管道中
                write(STDOUT_FILENO, &pipe_buf, 1);/*读取成功，输
            close(pipe_fd[0]); /*关闭读取端*/
            return 0; /*成功*/
        } else {  /*父进程中的操作*/
            close(pipe_fd[0]);  /*和子进程相对应，关闭读取端*/
            write(pipe_fd[1], "H", 1);/*写入一个字符“H”*/
            close(pipe_fd[1]);  /*关闭写入端*/
            wait(NULL);  /*等待子进程*/
            return 0;/*成功*/
        }
    }
```

这个例子的结果就是父进程向管道写入一个“H”字符，然后子进程读取后输出。从中可以学到：

（1）Linux提供了pipe接口来打开一个管道。函数原型如下：

```
int pipe(int pipefd[2], int flags);
```

其中第一个参数代表了成功打开后的管道的两端。

（2）根据fork的特性，当child_pid等于0时，代表的是子进程；否则，是父进程。所以，最后的“if”，“else”部分分别对管道执行了读和写操作。

（3）示例中因为父子进程间的特殊关系，使得两者共享管道文件描述符（即变量pipe_fd）成为可能。读者肯定会想到，如果两个进程没有任何关系怎么办呢？

对于这个范例，答案就是“无法实现”。

这也就是后来“Named Pipe”（也被称为FIFO）得以发展的原因。作为Pipe的扩展，它改变了前者的“匿名”方式。另外，Named Pipe的生命周期也不再是随进程结束而完结，其“system-persistent”特性要求我们在不使用它时一定要主动删除。

关于Named Pipe的更多信息，建议读者作为练习自行查阅相关资料。

4.3.3 UNIX Domain Socket

不少读者因为学习TCP/IP协议才接触到Socket，它在网络（比如Internet）通信领域获得了广泛的应用，被称为Network Socket。对于运行在同一机器内的进程间通信，Network Socket也完全能够胜任，只不过执行效率未必让人满意。

UNIX Domain Socket（UDS）是专门针对单机内的进程间通信提出来的，有时也被称为IPC Socket。两者虽然在使用方法上类似，但内部实现原理却有着很大区别。大家所熟识的Network Socket是以TCP/IP协议栈为基础的，需要分包、重组等一系列操作。而UDS因为是本机内的“安全可靠操作”，实现机制上并不依赖于这些协议。

Android中使用最多的一种IPC机制是Binder，其次就是UDS。相关资料显示，2.2版本以前的Android系统，曾使用Binder作为整个GUI架构中的进程间通信基础。后来因某些原因不得不弃之而用UDS，可见后者还是有一定优势的。

使用UDS进行进程间通信的典型流程如图4-7所示。

如果读者做过Internet Socket的开发，一定会觉得图4-7非常熟悉。UDS的基本流程与传统Socket一致，只是在参数上有所区分。下面向读者提供一个UDS的范例，功能如下：

- 服务器端监听IPC请求；
- 客户端发起IPC申请；
- 双方成功建立起IPC连接；

- 客户端向服务器端发送数据，证明IPC通信是有效的。

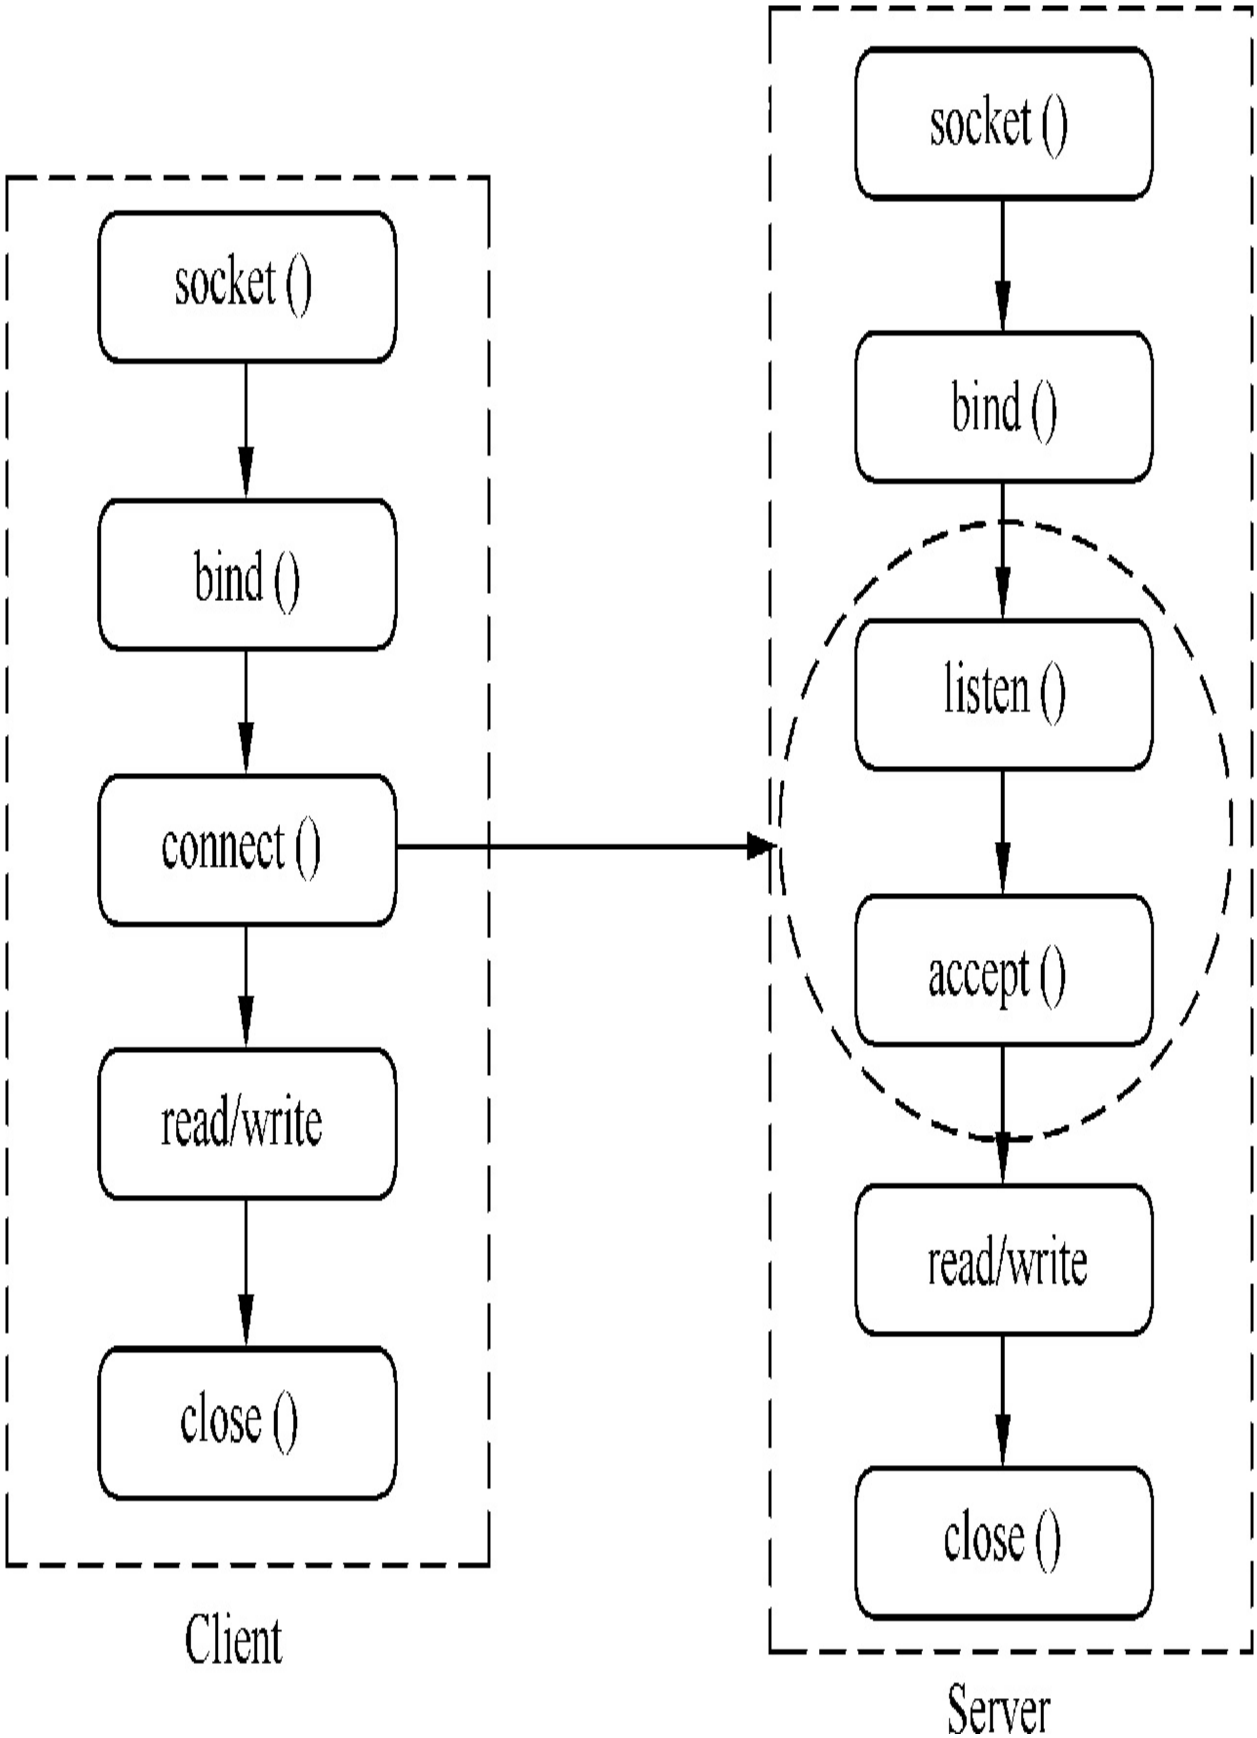

socket ()
bind ()
connect ()
read/write
close ()
Client
socket ()
bind ()
listen ()
accept ()
read/write
close ()
Server

▲图4-7　UNIX Domain Socket的通信流程

源码分为Client和Server两部分：

```
/*Server端代码*/
#include <stdio.h>
#include <stdlib.h>
#include <errno.h>
#include <string.h>
#include <sys/socket.h> //引用的是socket头文件
#include <sys/un.h>
#include <sys/types.h>

#define UDS_PATH  "uds_test"
int main(void)
{
     int socket_srv=-1;
     int socket_client=-1;
     int t=-1;
     int len=0;
     struct sockaddr_un  addr_srv, addr_client; /*注意地址格式与Netw
     char str[100];//用于接收通信数据
     memset(str, 0, sizeof(char)*100);//初始化

     if ((socket_srv = socket(AF_UNIX, SOCK_STREAM, 0)) <0) {/*首
                                       系统支持AF_INET，AF_UNIX，AF_N
                                       UDS对应于AF_UNIX，而不是AF_INE
          return -1;
     }
     addr_srv.sun_family = AF_UNIX;
     strcpy(addr_srv.sun_path, UDS_PATH); //设置path name
     if(bind(socket_srv, (struct sockaddr *)&addr_srv,offsetof(st
          + strlen(addr_srv.sun_path))<0) {/*将这个socket与地址进行
     return -1;
    }

    if (listen(socket_srv, 10) <0) {/*开始监听客户端的连接请求。第二个
     return -1;
    }

    while(1) {
         int nRecv;
         sz = sizeof(addr_client);
         if ((socket_client = accept(socket_srv, (struct sockaddr
                                   == -1) {/*要特别注意，accept返回的socke
                                         同一个。另外addr_client是客户
```

```
            return -1;
        }
        if (nRecv =recv(socket_client, str, 100, 0)<0) {/*接收数
            close(socket_client);
            break;
        }
        if (send(socket_client, str, nRecv, 0) < 0) {/*将接收到的
            close(socket_client);
            break;
        }
        close(socket_client);//传输完毕，关闭连接
    }
    return 0;
}
```

客户端代码如下：

```
#include <stdio.h>
#include <stdlib.h>
#include <errno.h>
#include <string.h>
#include <sys/socket.h> //也是引用socket头文件
#include <sys/un.h>
#include <sys/types.h>

#define UDS_PATH "uds_test"

/*客户端的部分操作和服务器是类似的，我们不再赘述*/
int main(void)
{
    int socket_client =-1;
    int data_len =0;
    int addr_size =0;
    struct sockaddr_un addr_srv;
    char str[100];
    memset(str, 0, sizeof(char)*100);
    strcpy(str, "This is a test for UDS");

    if ((socket_client = socket(AF_UNIX, SOCK_STREAM, 0)) <0) {
     return -1;
    }

    addr_srv.sun_family = AF_UNIX;
    strcpy(addr_srv.sun_path, UDS_PATH);
    addr_size = offsetof(struct sockaddr_un, sun_path) + strlen(a
    if (connect(socket_client, (struct sockaddr *)&addr_srv, addr
```

处于监听状态，Client则通过

```
        return -1;
    }

    if (send(socket_client, str, strlen(str), 0) <0) {/*发送数据给月
        close(socket_client);
        return -1;
    }
    if ((data_len=recv(socket_client, str, 100, 0)) > 0) {/*接收服
        str[data_len] = '\0';
        printf("echo from server: %s", str);
    } else {
        close(socket_client);
        return -1;
    }
    close(socket_client);
    return 0;
}
```

可以看到，建立一个Unix Domain Socket的过程还是相对烦琐的，特别是服务器端进程。考虑到这一点，UDS特别提供了一个便捷的函数，即socketpair()——它可以大大简化通信双方的工作，因而在实际项目中有不少应用。

后续章节在对Android系统的分析过程中，还会碰到基于UDS的进程间通信，希望本小节讲解的知识和范例可以帮助大家打下一定的基础。

4.3.4 RPC（Remote Procedure Calls）

从名称上可以看出，RPC涉及的通信双方通常运行于两台不同的机器中。在RPC机制中，开发人员不需要特别关心具体的中间传输过程是如何实现的，这种“透明性”可以较大程度地降低研发难度，如图4-8所示。

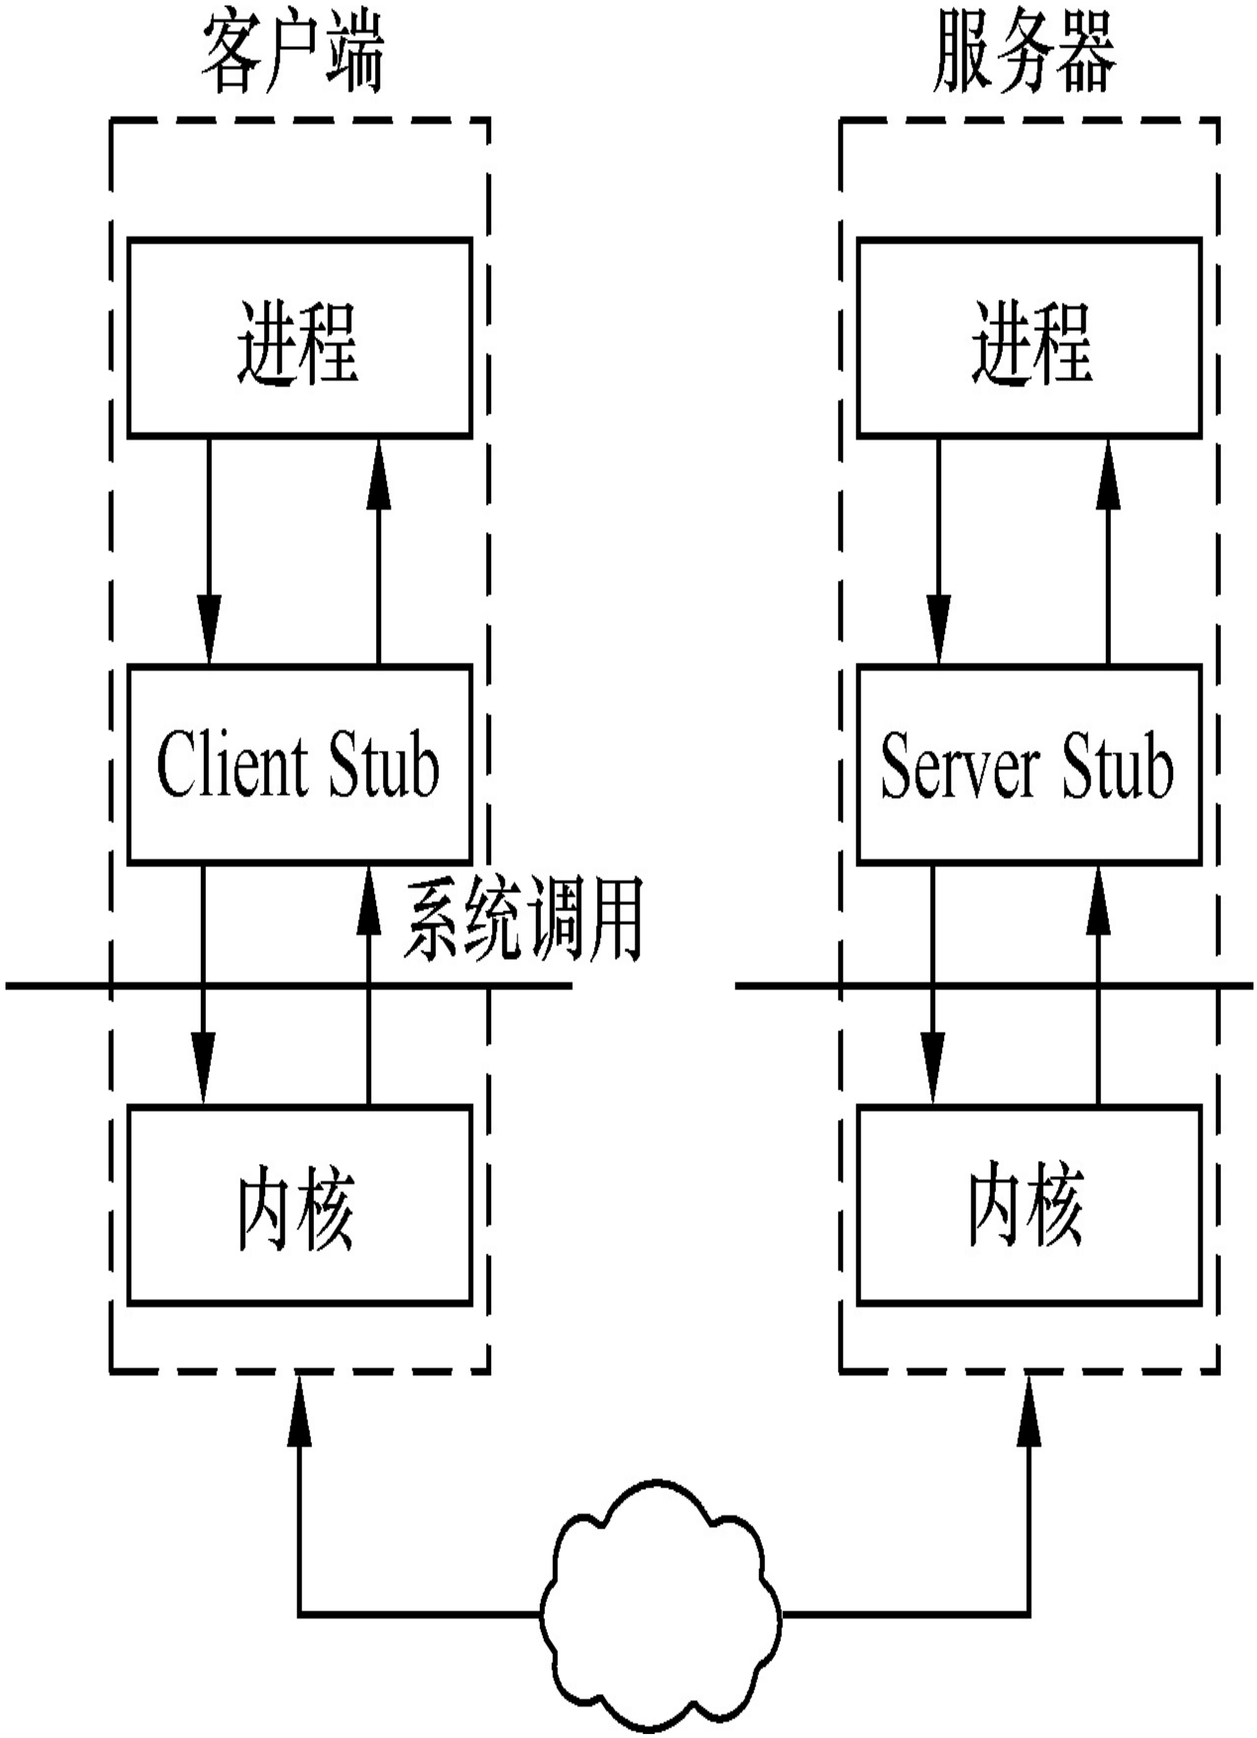

客户端
服务器
进程
进程
Client Stub
Server Stub
系统调用
内核
内核

▲图4-8　RPC通信图释

一般而言，一个完整的RPC通信需要以下几个步骤：

- 客户端进程调用Stub接口；
- Stub根据操作系统的要求进行打包，并执行相应的系统调用；
- 由内核来完成与服务器端的具体交互，它负责将客户端的数据包发给服务器端的内核；
- 服务器端Stub解包并调用与数据包匹配的进程；
- 进程执行操作；
- 服务器以上述步骤的逆向过程将结果返回给客户端。

4.4　同步机制的经典实现

既然操作系统支持多个进程（多线程）的并发执行，那么它们之间难免会出现相互制约的情况。比如两个进程（线程）需要共享唯一的硬件设备，或者同一块内存区域；又或者像生产流水线一样，进程（线程）的工作依赖于另一方对共享资源的执行结果——换句话说，它们存在协同关系。同步机制不但是操作系统的实现重点，在应用程序的设计中也具有举足轻重的作用，因而有必要先对它们进行集中分析。

从定义上来讲，如果多个（包括两个）进程间存在时序关系，需要协同工作以完成一项任务，则称为同步；如果它们并不满足协同的条件，而只是因为共享具有排他性的资源时所产生的关系，则称为互斥。当然，这样的理论定义既枯燥又难懂，大家可以结合具体的例子来理解。

互斥（Mutual Exclusion）问题是由荷兰专家Edsger W.Dijkstra于1965年在一篇名为《Solution of a problem in concurrent programming control》的Paper中首次提出的。经过几十年的发展，互斥机制已经得到了广泛的应用，并出现了很多有效的解决方案——这其中既有硬件的实现，也有软件的实现，本书介绍的重点是后者。

接下来我们将分若干小节详细讲解操作系统中常见的几种同步机制，然后在此基础上分析Android系统具体是如何实现同步机制的。

4.4.1 信号量（Semaphore）

信号量与PV原语操作是由Dijkstra发明的，也是使用最为广泛的互斥方法之一。它包括以下几个元素：

- Semaphore S（信号量）；
- Operation P（来自荷兰语proberen，意为test），有时也表达为wait()；
- Operation V（来自荷兰语verhogen，意为increment），有时也表达为signal()。

Semaphore S用于指示共享资源的可用数量。P原语可以减小S计数，V则增加它的计数。由此可知当某个进程想进入共享区时，首先要执行P操作；同理，想退出共享区时执行V操作。PV原语都属于原子操作（Atomic Operations），意味着它们的执行过程是不允许被中断的。

描述PV原语如图4-9所示。

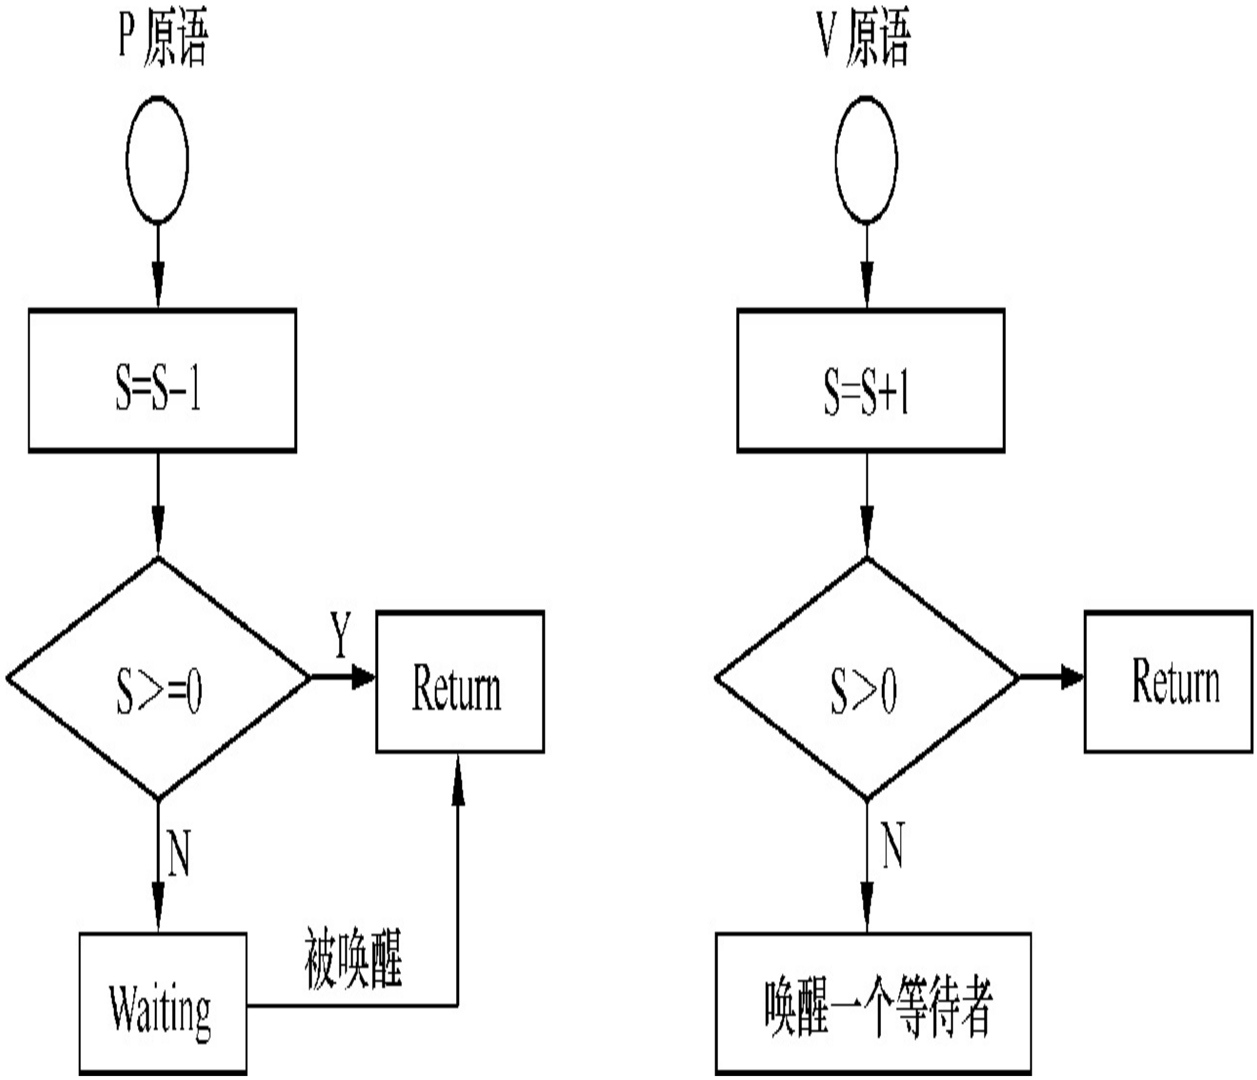

▲图4-9　PV操作图

P操作的执行过程：

- 信号量S自减1；
- 如果此时S仍然≥0，说明共享资源此时是允许访问的，因而调用者将直接返回，然后开始操作共享资源；
- 否则的话就要等待别人主动释放资源，这种情况下调用者会被加入等待队列中，直到后续被唤醒；
- 当某人释放了共享资源后，处于等待队列中的相关（取决于具

体情况）对象会被唤醒，此时该对象就具备了资源的访问权。

V操作的执行过程：

- 信号量S自增1；
- 此时如果S>0，说明当前没有希望访问资源的等待者，所以直接返回；
- 否则V操作要唤醒等待队列中的相关对象，对应P操作中的最后一步。

由此可见，Dijkstra的信号量机制只需要有限的几个元素和简单的操作就能解决同步问题，这也是它能产生深远影响的一大原因。

4.4.2 Mutex

Mutex是Mutual Exclusion的缩写，其释义为互斥体。那么，它和Semaphore有什么区别和联系呢？

根据计算机领域的普遍观点，如果资源允许多个对象同时访问，称为Counting Semaphores；而对于只允许取值0或1（即locked/unlocked）的Semaphore，则叫作Binary Semaphore。后者可以认为与本小节的Mutex具有相同的性质。换句话说，Mutex通常是对某一排他资源的共享控 制——要么这个资源被占用（locked），要么就是可以访问的（unlocked）。在很多操作系统中，Binary Semaphore和Mutex没有本质差异，前者是特定的Semaphore机制，而后者相较于Semaphore在实现上则更为简单。

4.4.3 管程（Monitor）

管程是由C.A.R.Hoare和Per Brinch Hansen提出来的，并在Hansen’s Concurrent Pascal Language中得到实现。它实际上是对Semaphore机制的延伸和改善，是一种控制更为简单的同步手段。

根据前面的分析，我们知道Semaphore机制要求用户成对配套地使用P和V操作原语。对于简单的应用场合，这不容易引发问题。而一旦涉及庞大且复杂的系统，就难免让人产生“不识庐山真面目，只缘身在此

山中”的感觉。这就好比C/C++语言中的new/delete操作，假如只是简短的几句代码，通常不会产生内存泄露的问题。可如果是写一个操作系统呢？其中的工作量大得惊人，而且一定会是由很多人协作完成的。在这种情况下，如果没有很好的机制来约束内存的分配和释放，那么产生内存泄露、野指针等问题的可能性就很大了。

采用Semaphore机制的程序易读性相对较差，对于信号量的管理也分散在各个参与对象中，因而有可能由此引发一系列问题，如死锁、进程饿死等。为了使资源的互斥访问更利于维护，科学家们提出了管程的概念。如下：

管程（Monitor）是可以被多个进程/线程安全访问的对象（object）或模块（module）。

管程中的方法都是受mutual exclusion保护的，意味着在同一时刻只允许有一个访问者使用它们。另外，管程还具备如下属性：

- 安全性;
- 互斥性;
- 共享性。

很多流行的编程语言中都实现了管程机制，如Delphi、Java、Python、Ruby、C#等。

4.4.4 Linux Futex

Futex（Fast Userspace muTEXes）是由Hubertus Franke等人发明的一种同步机制，首次出现在Linux 2.5.7版本，并在2.6.x中成为内核主基线的一部分。它的核心优势已经体现在其名称中了，即“Fast”。Futex的“快”主要体现于它在应用程序空间中就可以应对大多数的同步场景（只有当需要仲裁时才会进入内核空间），这样一来节省了不少系统调用和上下文切换的时间。

Futex在Android中的一个重要应用场景是ART虚拟机。如果Android版本中开启了ART_USE_FUTEXES宏，那么ART虚拟中的同步机制就会以Futex为基石来实现。下面所示的就是ART中使用相当频繁的互斥机制：

```
/*art/runtime/base/mutex.cc*/
```

```
void Mutex::ExclusiveLock(Thread* self) {…
  if (!recursive_|| !IsExclusiveHeld(self)) {
#if ART_USE_FUTEXES //通过Futex来实现互斥加锁
    bool done = false;
    do {
      int32_t cur_state = state_.LoadRelaxed();
      if (LIKELY(cur_state == 0)) {
        done = state_.CompareExchangeWeakAcquire(0 /* cur_state *
      } else {
        ScopedContentionRecorder scr(this, SafeGetTid(self), GetE
        num_contenders_++;
        if (futex(state_.Address(), FUTEX_WAIT, 1, nullptr, nullp
          if ((errno != EAGAIN) && (errno != EINTR)) {
            PLOG(FATAL) << "futex wait failed for " << name_;
          }
        }
        num_contenders_--;
      }
    } while (!done);
    DCHECK_EQ(state_.LoadRelaxed(), 1);
#else //不启用Futex的情况下，通过传统的pthread来实现
    CHECK_MUTEX_CALL(pthread_mutex_lock, (&mutex_));
#endif
    DCHECK_EQ(exclusive_owner_, 0U);
    exclusive_owner_= SafeGetTid(self);
    RegisterAsLocked(self);
  }
  recursion_count_++;
  …
}
```

上述的Mutex加锁操作可以分为两部分，其一是开启了ART_USE_FUTEXES的情况，此时通过Futex来实现;其二则是使用传统的pthread API来完成相同的功能。

其中state_是一个AtomicInteger变量，而AtomicInteger的定义如下：

```
typedef Atomic<int32_t> AtomicInteger;
```

即原子类型的int32。

Mutex加锁的基本逻辑是：如果可以获取到锁，则直接返回；否则就进入挂起状态。第二种情况下是调用futex函数来完成的，后者由

bionic提供，它会在内部使用到SYS_futex这个系统调用。

函数futex共有6个参数，其原型如下所示：

```
static inline int futex(volatile int *uaddr, int op, int val, con
                        volatile int *uaddr2, int val3)
```

第一个参数uaddr指向的是futex word——即一个4字节的interger，在我们这个场景中具体对应的是state_。

第二个参数op代表operation，即需要执行的操作，目前只支持两种，即FUTEX_WAIT和FUTEX_WAKE。

第三个参数val的含义根据op的不同而有所差异。

后面几个参数只有在某些特殊情况下才需要，在我们这个场景中可以直接略过。

如果调用futex时提供的操作指令是FUTEX_WAIT，通常意味着futex word保持val值（acquired）可能需要等待较长时间。可以看到，我们利用原子操作在用户态获取到了futex word，然后调用futex函数——这两个操作之间有一个明显的时间差。换句话说，当我们调用futex时情况有可能已经变化了。这也是需要在futex的第一个参数传入futex word的原因之一，即内核可以据此自行判断当前的最新状态。

对于不存在竞争的情况下，采用futex机制在用户态就可以完成锁的获取，而不需要通过系统调用进入内核态，从而提高了效率。

4.4.5 同步范例

理解了以上几种同步机制的原理后，我们再来分析一个范例，即经典的生产者与消费者问题。Android系统源码中有多个地方都应用了这个经典模型，如音频子系统里AudioTrack和AudioFlinger间的数据交互。

相信读者对此问题（“The producer-consumer problem”，也称为“The bounded-buffer problem”）并不陌生。描述如下：

两个进程共享一块大小为N的缓冲区——其中一个进程负责往里填

充数据（生产者），而另一个进程则负责往里读取数据（消费者）。问题的核心有两点：

- 当缓冲区满时，禁止生产者继续添加数据，直到消费者读取了部分数据后；
- 当缓冲区空时，消费者应等待对方继续生产后再执行操作。

具体如图4-10所示。

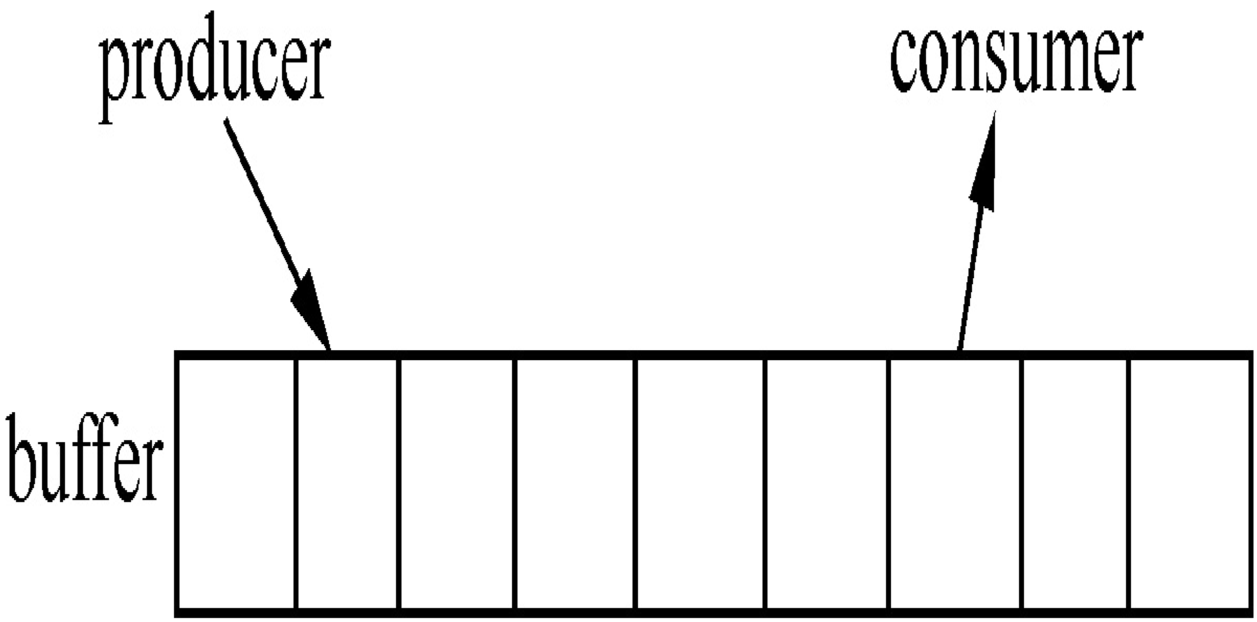

▲图4-10　The producer-consumer problem

如果使用信号量来解决这个问题，需要用到3个Semaphore。功能分别如下：

- S_emptyCount：用于生产者获取可用的缓冲区空间大小，初始值为N。
- S_fillCount：用于消费者获取可用的数据大小，初始值为0。
- S_mutex：用于操作缓冲区，初始值为1。

对于生产者来说，执行步骤如下：

- 循环开始；

- Produce_item;
- P（S_emptyCount）；
- P（S_mutex）；
- Put_item_to_buffer;
- V（S_mutex）；
- V（S_fillCount）；
- 继续循环。

对于消费者来说，执行步骤如下：

- 循环开始;
- P（S_fillCount）；
- P（S_mutex）；
- Read_item_from_buffer;
- V（S_mutex）；
- V（S_emptyCount）；
- Consume;
- 继续循环。

一开始，S_emptyCount的值为N，S_fillCount的值为0，所以消费者在P（S_fillCount）后处于等待状态。而生产者首先生产一件产品，然后获取S_emptyCount——因为它为N，处于可访问状态，所以产品可以被放入buffer中。之后生产者通过V（S_fillCount）来增加可用产品的计数，并唤醒正于这个Semaphore上等待的消费者。于是消费者开始

读取数据，并利用V（S_emptyCount）来表明buffer又空出了一个位置。

生产者和消费者就是如此循环反复来完成整个工作，这样我们就通过Semaphore机制保证了生产者和消费者的有序执行。

4.5 Android中的同步机制

学习了操作系统中同步机制的基础原理后，我们再来看Android具体是如何做的，又有哪些改进。值得一提的是，不论什么样的操作系统，其技术本质都类似，而更多的是把这些核心的理论应用到符合自己需求的场景中。目前Android封装的同步类包括：

- Mutex

头文件是frameworks/native/include/utils/Mutex.h

Android中的Mutex只是对pthread提供的API的简单再封装，所以函数声明和实现体都放在同一个头文件中，这样做也方便了调用者的操作。

另外，Mutex中还包含一个AutoLock的嵌套类，它是利用变量生命周期特点而设计的一个辅助类。

- Condition

头文件是frameworks/native/include/utils/Condition.h

Condition是“条件变量”在Android系统中的实现类，后面的分析中我们将看到它是依赖Mutex来完成的。

- Barrier

头文件是frameworks/native/services/surfaceflinger/Barrier.h

Barrier是同时基于Mutex和Condition实现的一个模型。本书在AudioFlinger和SurfaceFlinger这两个章节都会碰到它的使用场景，并做了详尽的分析。建议大家以理论结合实例来理解，这样可能会事半功倍。

4.5.1 进程间同步——Mutex

我们先来看Mutex类中的一个enum定义。如下所示：

```
class Mutex {
public:
    enum {
        PRIVATE = 0,//只限同一进程间的同步
        SHARED = 1//支持跨进程间的同步
    };
```

这说明Mutex既可以处理进程内同步的情况，也能完美解决进程间同步的问题。

如果在Mutex构造时指定它的type是SHARED的话，说明它是适用于跨进程共享的。此时Mutex将进一步调用pthread_mutexattr_setpshared接口来为这个互斥量设置PTHREAD_PROCESS_SHARED属性。Android中使用SHARED类型Mutex的地方有不少，如本书音频系统章节中AudioTrack与AudioFlinger就驻留在两个不同的进程中，所以它们的Mutex变量就是以如下方式构造的：

```
frameworks/av/media/libmedia/AudioTrack.cpp*/
audio_track_cblk_t::audio_track_cblk_t():
lock(Mutex::SHARED), cv(Condition::SHARED), user(0), server(0), …
{…
}
```

与Semaphore不同的是，Mutex只有两种状态，即0和1。所以这个类只提供了3个重要的接口函数：

```
    status_t    lock(); //获取资源锁
    void       unlock(); //释放资源锁
    status_t    tryLock(); /*不论成功与否都会及时返回，而不是等待*/
```

当调用者希望访问临界资源时，它必须先通过lock()来获得资源锁。如果此时资源可用，这个函数将马上返回；否则，会进入阻塞等待，直到有人释放了资源锁并唤醒它。释放资源锁调用的是unlock()，同时正在等待使用这个锁的其他对象就会被唤醒，然后继续执行它的任务。另外，Mutex还特别提供了一个tryLock()来满足程序的多样化需求。这个函数仅会“试探性”地查询资源锁是否可用——如果答案是肯定的就获取它，然后成功返回（返回值为0），从这一点看它和lock()的表现是一样的；但在资源暂不可用的情况下，它并不会进入等待，而同样是立即返回，只是返回值不为0。

这三个函数的实现很简单，具体源码如下：

```
inline status_t Mutex::lock() {
    return -pthread_mutex_lock(&mMutex);//变量mMutex的类型是pthread_
}
inline void Mutex::unlock() {
    pthread_mutex_unlock(&mMutex);
}
inline status_t Mutex::tryLock() {
    return -pthread_mutex_trylock(&mMutex);
}
```

所以我们说，Mutex实际上只是基于pthread接口的再封装。

4.5.2　条件判断——Condition

Condition的字面意思是“条件”。换句话说，它的核心思想是判断“条件是否已经满足”——满足的话马上返回，继续执行未完成的动作；否则就进入休眠等待，直到条件满足时有人唤醒它。

可能有读者会问，这种情况用Mutex能实现吗？理论上讲，的确是可以的。举一个例子，假设两个线程A和B共享一个全局变量vari，且它们的行为如下。

Thread A：不断去修改vari，每次改变后的值未知。

Thread B：当vari为0时，它需要做某些动作。

显而易见，A和B都想访问vari这个共享资源，属于Mutex的问题领域。但需要商榷的细节是：线程A的“企图”仅仅是获得vari的访问权；而线程B则“醉翁之意不在酒”，其真正等待的条件是“vari等于0”。

那么如果用Mutex去完成的话，线程B就只能通过不断地读取vari来判断条件是否满足，有点类似于下面的伪代码：

```
while(1)//死循环，直到条件满足时退出
{
    acquire_mutex_lock(vari);//获取vari的Mutex锁
    if(0 == vari) //条件满足
    {
```

```
        release_mutex_lock(vari);//释放锁
        break;
    }
    else
    {
      release_mutex_lock(vari);//释放锁
        sleep();//休眠一段时间
    }
}
```

对于线程B而言，什么时候达到条件（vari==0）是未知的，这点和其他只是使用vari的线程（比如线程A）有很大不同，因而采用轮询的方式显然极大地浪费了CPU时间。

再举一个生活中的例子，以加深大家的理解。比如有一个公共厕所，假设同时只能供一个人使用。现在把希望使用这一资源的人分为两类：其一当然是正常使用厕所的用户（类似于线程A）；其二就是更换厕纸的工作人员（类似于线程B）。如果我们使用Mutex来解决这一资源同步共享问题，会发生什么情况呢？

首先对于用户来说并不会产生太大的影响，他们仍然正常排队、使用、归还。

但对于工作人员来说就有点麻烦了。在Mutex机制下，工作人员也需要和其他人一样正常排队。只有等排到他时，他才能进去看下厕纸是否用完——用完就更换，否则就什么也不做直接退出，然后继续排队等待，如此循环往复。假设排一次队需要5分钟，而工作人员进去后需要更换厕纸的概率只有1/10。那么可想而知，这位工作人员的效率是相当低的，因为他的时间都浪费在等待“厕纸为空”上了。

所以，我们需要寻找另一种模型来解决这一特殊的同步场景。

可行的方法之一是工作人员不需要排队，而是由其他人通知他厕所缺纸的事件。这样做既减少了排队人员的数量，提高了资源的使用率，同时也改善了工作人员的办事效率，可谓一举两得。

Condition就是按照这样的思路提出来的：

```
class Condition {
public:
    enum { //和Mutex一样，它支持跨进程共享
```

```
        PRIVATE = 0,
        SHARED = 1
    };
     …
    status_t wait(Mutex& mutex); //在某个条件上等待
    status_t waitRelative(Mutex& mutex, nsecs_t reltime); /*也是在
                                                     时退出功能*/
    void signal(); //条件满足时通知相应等待者
    void broadcast(); //条件满足时通知所有等待者
private:
#if defined(HAVE_PTHREADS)
    pthread_cond_t mCond;
#else
    void*   mState;
#endif
};
```

从Condition提供的几个接口函数中，我们有如下疑问。

- 既然wait()是在等待某个“条件”满足，那么如何去描述这个“条件”呢？

在整个Condition类的源码实现中，我们都看不到与条件相关的变量或者操作。这是因为，Condition实际上是一个“半成品”，它并不理会具体的“条件”是什么样的——理由很简单，在不同的情况下，用户所设定的“条件”形式都可能不同。Condition想要提供一种“通用的解决方案”，而不是针对某些具体的“条件样式”去设计。比如“条件”既可能是“某变量A为True”，也可以是“变量A达到值100”，或者“变量A等于B”等。这些是Condition所无法预料的，因此它能做的就是提供一个“黑盒”及“黑盒”的操作手法，而不必去理会盒子里是什么。

- 为什么需要mutex?

相信大家都注意到了，wait和waitRelative接口都带有一个Mutex& mutex变量，这是很多人不解的地方——既然都有Condition这一互斥方法了，为什么还要把Mutex牵扯进来呢？

由于Condition本身的不完整性，如果直接从理论角度分析估计比较生硬，所以我们将结合下一小节的Barrier来为大家解答上述两个问题。

4.5.3 “栅栏、障碍”——Barrier

Condition表示“条件”，而Barrier表示“栅栏、障碍”。后者是对前者的一个应用，即Barrier是填充了“具体条件”的Condition，这给我们理解Condition提供了一个很好的范例：

顺便提一下，Barrier类是专门为SurfaceFlinger而设计的，并不是像Mutex，Condition一样作为常用的Utility提供给整个Android系统使用。不过，这不影响我们对它的分析：

```
/*frameworks/native/services/surfaceflinger/Barrier.h*/
class Barrier
{
public:
    inline Barrier() : state(CLOSED) { }
    inline ~Barrier() { }
    void open() {
        Mutex::Autolock _l(lock);
        state = OPENED;
        cv.broadcast();
    }
    void close() {
        Mutex::Autolock _l(lock);
        state = CLOSED;
    }
    void wait() const {
        Mutex::Autolock _l(lock);
        while (state == CLOSED) {
            cv.wait(lock);
        }
    }
private:
    enum { OPENED, CLOSED };
    mutable     Mutex       lock;
    mutable     Condition   cv;
    volatile    int         state;
};
```

Barrier总共提供了3个接口函数，即wait()，open()和close()。既然说它是Condition的实例，那么“条件”是什么呢？稍微观察一下就会发现，是其中的变量state==OPENED；另一个状态当然就是CLOSED——这有点类似于汽车栅栏的开启和关闭。在汽车通过前，它必须要先确认栅栏是开启的，于是调用wait()。如果条件不满足，那么汽车就只

能停下来等待。这个函数首先获取一个Mutex锁，然后才是调用Condition对象cv，为什么呢？我们知道Mutex是用于保证共享资源的互斥使用的，这说明wait()中接下来的操作涉及了对某一互斥资源的访问，即state这个变量。可以想象一下，假如没有一把对state访问的锁，那么当wait与open/close同时去操作它时，有没有可能引起问题呢？

假设有如下步骤。

Step 1. 线程A通过wait()取得state值，发现是CLOSED。

Step 2. 线程B通过open()取得state值，将其改为OPENED。

Step 3. open()唤醒正在等待的线程。因为此时线程A还没有进入睡眠，所以实际上没有线程需要唤醒。

Step4. 另外，线程A因为state==CLOSED，所以进入等待，但这时候的栅栏实际上已经开启了，这将导致wait()调用者所在线程得不到唤醒。

这样就很清楚了，对于state的访问必须有一个互斥锁的保护。

接下来，我们分析Condition::wait()的实现：

```
inline status_t Condition::wait(Mutex& mutex) {
    return -pthread_cond_wait(&mCond, &mutex.mMutex);
}
```

和Mutex一样，直接调用了pthread提供的API方法。

pthread_cond_wait的逻辑语义如下。

Step1. 释放锁mutex。

Step2. 进入休眠等待。

Step3. 唤醒后再获取mutex锁。

也就是经历了先释放，再获取锁的过程，为什么这么设计呢？

由于wait即将进入休眠等待，假如此时它不先释放Mutex锁，那么open()/close()又如何能访问“条件变量”state呢？这无疑会使程序陷入互相等待的死锁状态。所以它需要先行释放锁，再进入睡眠。之后因为open()操作完毕会释放锁，也就让wait()有机会再次获得这一Mutex锁。

同时我们注意到，判断条件是否满足的语句是一个while循环：

```
while (state == CLOSED) {…
```

这样做也是合理的。假设我们在close()的末尾也加一个broadcast()或者signal()，那么wait()同样会被唤醒，但是条件满足了吗？显然没有。所以wait()只能再次进入等待，直到条件真正为OPENED为止。

值得注意的是，wait()函数的结尾会自动释放Mutex锁（因为_l是一个Autolock变量，详见下一小节）。也就是说wait()返回时，程序已经不再拥有对共享资源的锁了。笔者认为，如果接下来的代码还有对共享资源的操作，那么就应该再次获取锁，否则还是会出错。举个前面的例子，当wait()返回时，我们的确可以认为此时汽车栅栏是已经打开的。但是因为释放了锁，很有可能在汽车发动的过程中，又有人把它关闭了。这导致的后果就是汽车会直接撞上栅栏而引起事故。Barrier通常被用于对某线程是否初始化完成进行判断，这种场景具有不可逆性——既然已经初始化了，那么后期就不可能再出现“没有初始化”的情况，因而即便wait()返回后没有获取锁也被认为是安全的。

条件变量Condition是和互斥锁Mutex同样重要的一种资源保护手段，大家务必要理解清楚。当然，我们更多的是从使用的角度去学习，至于pthread_cond_wait内部是如何实现的，因为涉及具体的硬件平台，可以暂时不去深究。

4.5.4　加解锁的自动化操作——Autolock

在Mutex类的内部还有一个Autolock嵌套类，从字面上看它应该是为了实现加、解锁的自动化操作，那么如何实现呢？

其实很简单，看看这个类的构造和析构函数大家就明白了：

```
class Autolock {
public:
    inline Autolock(Mutex& mutex) : mLock(mutex)  { mLock.loc
    inline Autolock(Mutex* mutex) : mLock(*mutex) { mLock.loc
    inline ~Autolock() { mLock.unlock(); }
private:
    Mutex& mLock;
};
```

也就是说，当Autolock构造时，会主动调用内部成员变量mLock的lock()方法来获取一个锁。而析构时的情况正好相反，调用它的unlock()方法释放锁。这样假如一个Autolock对象是局部变量的话，那么它在生命周期结束时就会自动把资源锁解。除了前一小节中遇到的_l变量外，我们再举个AudioTrack中的例子。如下所示：

```
/*frameworks/av/media/libmedia/AudioTrack.cpp*/
uint32_t audio_track_cblk_t::framesAvailable()
{
    Mutex::Autolock _l(lock);
    return framesAvailable_l();
}
```

变量_l是一个Autolock对象，它在构造时会主动去获取audio_track_cblk_t中的lock锁。而当framesAvailable()结束时，_l的生命周期也随之完结，于是它在析构函数中又会unlock这个锁。这虽然是一个不起眼的小技巧，但在某些情况下可以有效防止开发人员因没有配套使用lock/unlock而酿成“悲剧”。

4.5.5　读写锁——ReaderWriterMutex

Android Art虚拟机中用到互斥和锁操作的地方非常多，为此它实现了一整套自己的mutex机制，大家可以参考art/runtime/base目录并结合本书的虚拟机章节了解详情。

本小节我们重点分析一下Art虚拟机中的一种特殊mutex，即ReaderWriterMutex。从字面意思上来理解，它代表的是“读写锁”。与普通的mutex相比，它主要提供了如下一些差异接口：

```
void ExclusiveLock(Thread* self) ACQUIRE();
void ExclusiveUnlock(Thread* self) RELEASE();
bool ExclusiveLockWithTimeout(Thread* self, int64_t ms, int32_t n
     EXCLUSIVE_TRYLOCK_FUNCTION(true);
```

```
void SharedLock(Thread* self) ACQUIRE_SHARED() ALWAYS_INLINE;
void SharedUnlock(Thread* self) RELEASE_SHARED() ALWAYS_INLINE;
```

其中Exclusive和Shared分别代表Write和Read权限，这也很好地诠释了这种锁的特点是允许有多个对象共享Read锁，但同时却只能有唯一一个对象拥有Write锁。ReaderWriterMutex可以有以下3种状态。

- Free：还没有被任何对象所持有的情况。
- Exclusive：当前被唯一一个对象持有的情况。
- Shared：被多个对象持有的情况。

各个状态间所允许的操作及操作结果如表4-3所示。

表4-3　ReaderWriterMutex状态表

State	ExclusiveLock	ExclusiveUnlock	SharedLock	SharedUnlo
Free	Exclusive	error	SharedLock(1)	error
Exclusive	Block	Free	Block	error
Shared(n)	Block	error	SharedLock(n+1)	Shared(n-1) c Free

ReaderWriterMutex的内部实现并不复杂，它的基础仍然是普通的mutex，并且根据系统是否启用Futex在实现上会有所差异。大家可以参考/art/runtime/base/mutex.cc来了解详情。

4.6 操作系统内存管理基础

不论什么类型的操作系统，内存管理都是绝对的重点和难点。

简单来说，内存管理（Memory Management）旨在为系统中的所有Task提供稳定可靠的内存分配、释放与保护机制。可能有读者会问，我们学习Android系统还需要了解Linux Kernel的内存管理机制吗？

答案是肯定的。不论是Android中的音频系统、GUI系统，还是Binder的实现机理等，都与内存管理是息息相关的。甚至可以说，任何操作系统的运行都只是在“玩内存游戏”。当然，没有内核基础的读者也不要因此而觉得“前途漫漫无归路”，事实上“内存游戏”再精彩，其底层原理都基本不变。因此，需要重点理解以下几个核心：

- 虚拟内存；
- 内存分配与回收；
- 内存保护。

接下来我们将通过若干小节来和读者一起“补缺补漏”，从而为后续的Android学习扫清道路。

4.6.1 虚拟内存（Virtual Memory）

计算机出现的早期物理内存普遍很小，不过因为当时程序的体积也不大，所以不会有什么问题。然而随着软件的发展，动辄以GB为单位的程序比比皆是。在这种情况下，如何保证这些软件能在大多数机器上运行呢？

一种最直接的方式就是加大物理内存，使得机器能一次性读入任何程序。这样的“理想是很丰满的”，但“现实却很骨感”。且不论硬件的升级意味着成本的增加，即便把内存加大到16G以上，问题还是没有得到根本的解决——程序体积仍然可能超过它。换句话说，这样的设备是不可靠的，因为我们不清楚它什么时候会遭遇宕机。

虚拟内存的出现为大体积程序的运行提供了可能。它的基本思想

是。

- 将外存储器的部分空间作为内存的扩展，如从硬盘划分出4GB大小。
- 当内存资源不足时，系统将按照一定算法自动挑选优先级低的数据块，并把它们存储到硬盘中。
- 后续如果需要用到硬盘中的这些数据块，系统将产生“缺页”指令，然后把它们交换回内存中。
- 这些操作都是由操作系统内核自动完成的，对上层应用“完全透明”。

理解虚拟内存机制，首先要学习3种不同的地址空间。

1．逻辑地址（Logical Address）

它也称为“相对地址”，是程序编译后所产生的地址。逻辑地址由两部分组成：

- Segment Selector（段选择子）

用于描述逻辑地址所处的段，16bit。格式如下：

其中的TI指“Table Indicator”、RPL指“Request Privilege Level”。从TI的名称可以猜测到，它和某种“Table”有关。具体而言，就是GDT（Global Descriptor Table）及LDT（Local Descriptor Table）。它们都用于记录各种段描述符（Segment Descriptors），而表本身的存储地址则由GDTR和LDTR两个CPU寄存器来保存。GDT的有效范围是全局的，同时系统也允许各进程创建自己的本地表（LDT）以增加

额外的段。

这样就很清楚了，段选择子中的INDEX就是GDTR/LDTR中的“序号”——具体是哪个表，则由“Table Indicator”来区分：0表示GDT，1表示LDT。

- Offset

用于描述段内的偏移值，32bit。

CPU提供了专用的寄存器来承载段选择子，如表4-4所示。

表4-4　段寄存器

寄存器名称	描　　述
CS	Code Segment Register，代码段寄存器
DS	Data Segment Register，全局与静态数据段寄存器
SS	Stack Segment Register，堆栈段寄存器
ES	Extra Segment Register，附加数据段寄存器
FS	通用段寄存器
GS	

对于开启段页式内存管理的机器而言，逻辑地址需要经过两次变换才能得到最终的物理地址，如图4-11所示。

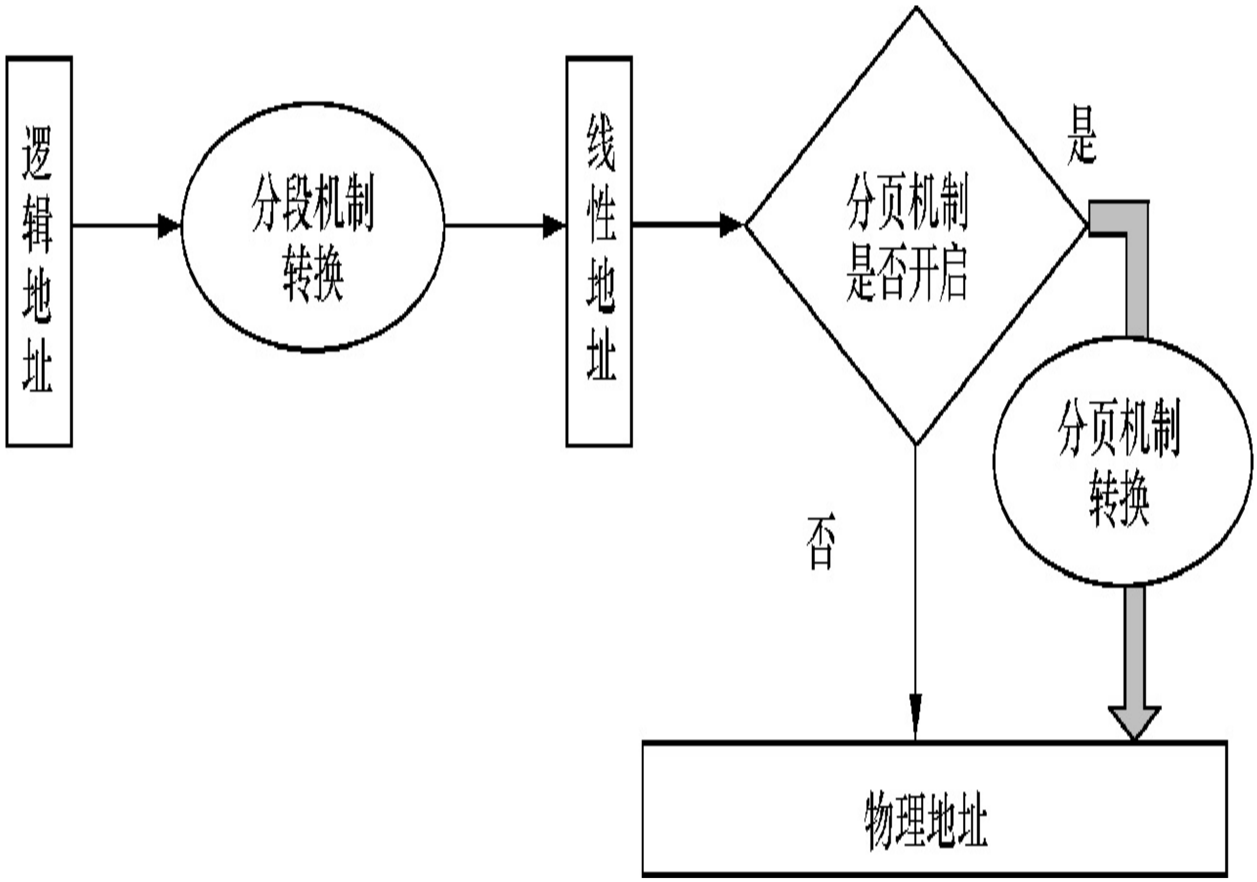

▲图4-11　地址空间的转换过程简图

早期的机器并没有任何虚拟地址的概念，被称为“实模式”内存管理。而后期发展出来的设备即使提供了虚拟地址的硬件实现，但为了兼容早期的操作系统，机器在开机时仍然会处于“实模式”——直到系统程序做好准备工作后才切换到相应的“保护模式”。

需要注意的是，并不是所有系统都同时支持段页式的内存管理。有些操作系统只提供了页式的管理机制，而Linux内核虽然理论上是段页式的，但也只是实现了分页机制（分段机制只用到其中一部分功能）。关于这部分内容，读者可以参考相关资料来了解。

2．线性地址（Linear Address）

线性地址是逻辑地址经过分段机制转换后形成的。其基本思想是。

- 根据段选择子中的TI字段，得知段描述符存储在GDT或者LDT中。

- 通过GDTR/LDTR获得GDT/LDT的存储地址。
- 根据段选择子中的INDEX字段，到GDT/LDT中查找到对应的段描述符。
- 根据段描述符获得此段的基地址。
- 由基地址+段内偏移值得到线性地址。

逻辑地址到线性地址的转换如图4-12所示。

3．物理地址（Physical Address）

物理地址空间很好理解，它是指机器真实的物理内存所能表示的地址空间范围。比如对于只有64KB内存的系统来说，其物理地址范围是0x0000～0xFFFF。任何操作系统，最终都需要通过真实的物理地址来访问内存。

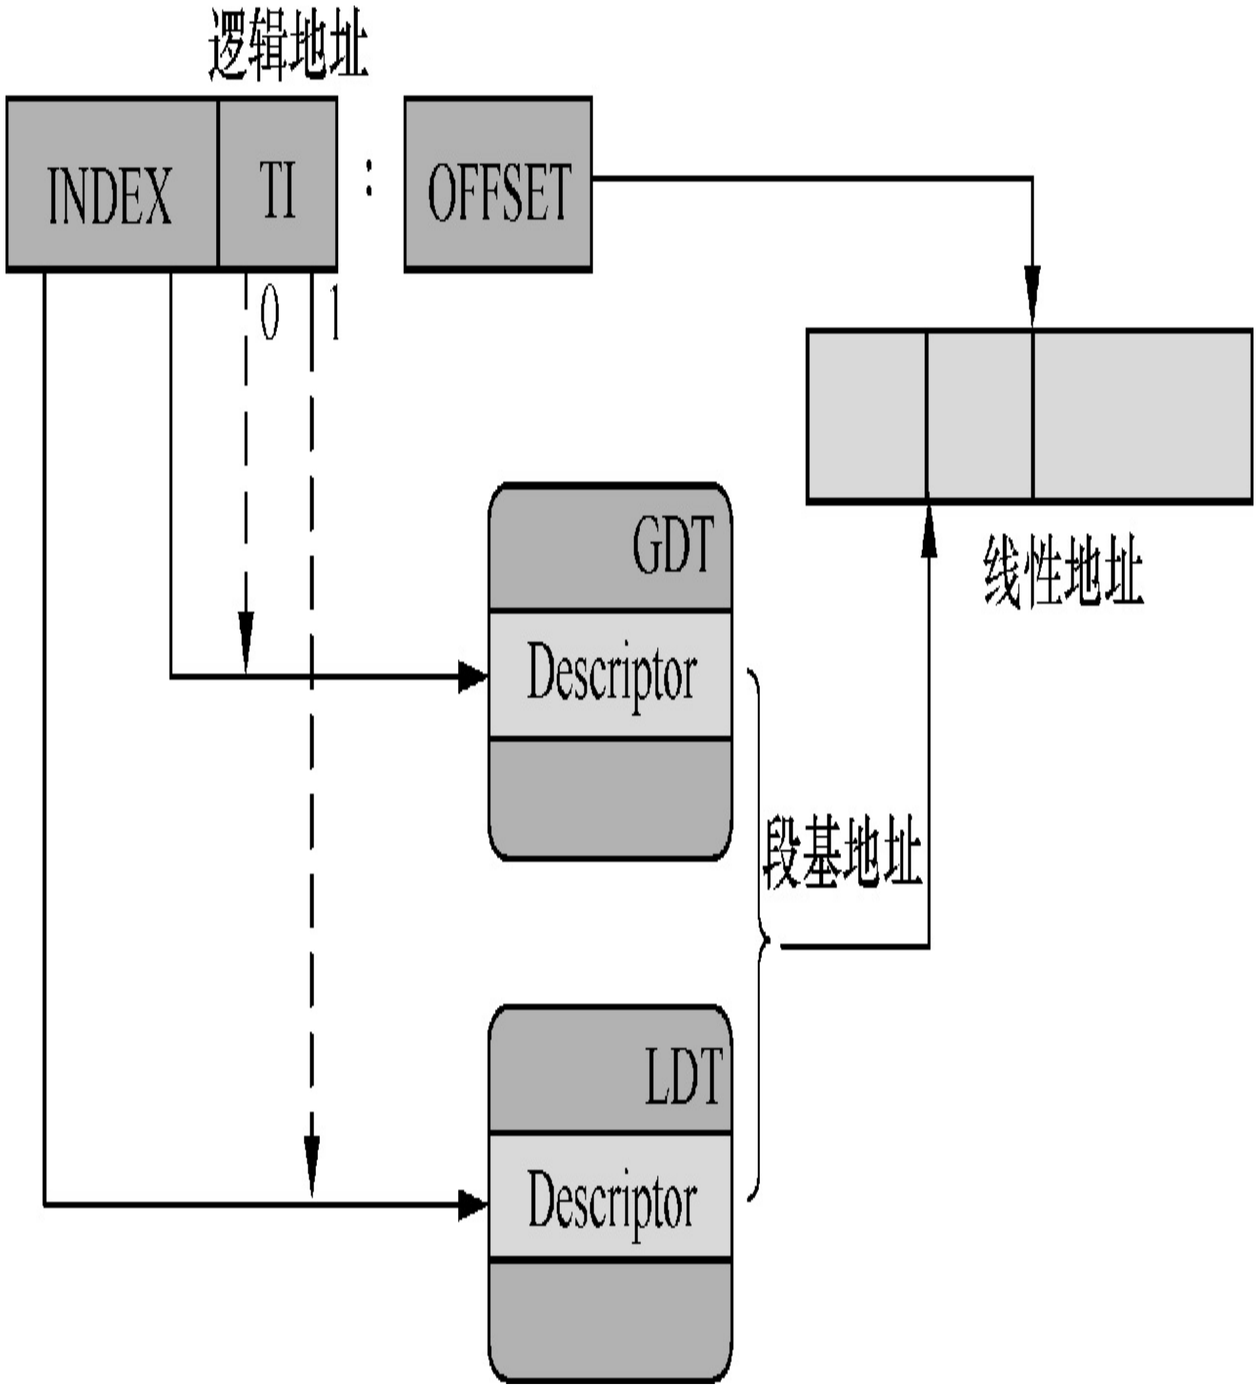

▲图4-12　逻辑地址到线性地址的转换简图

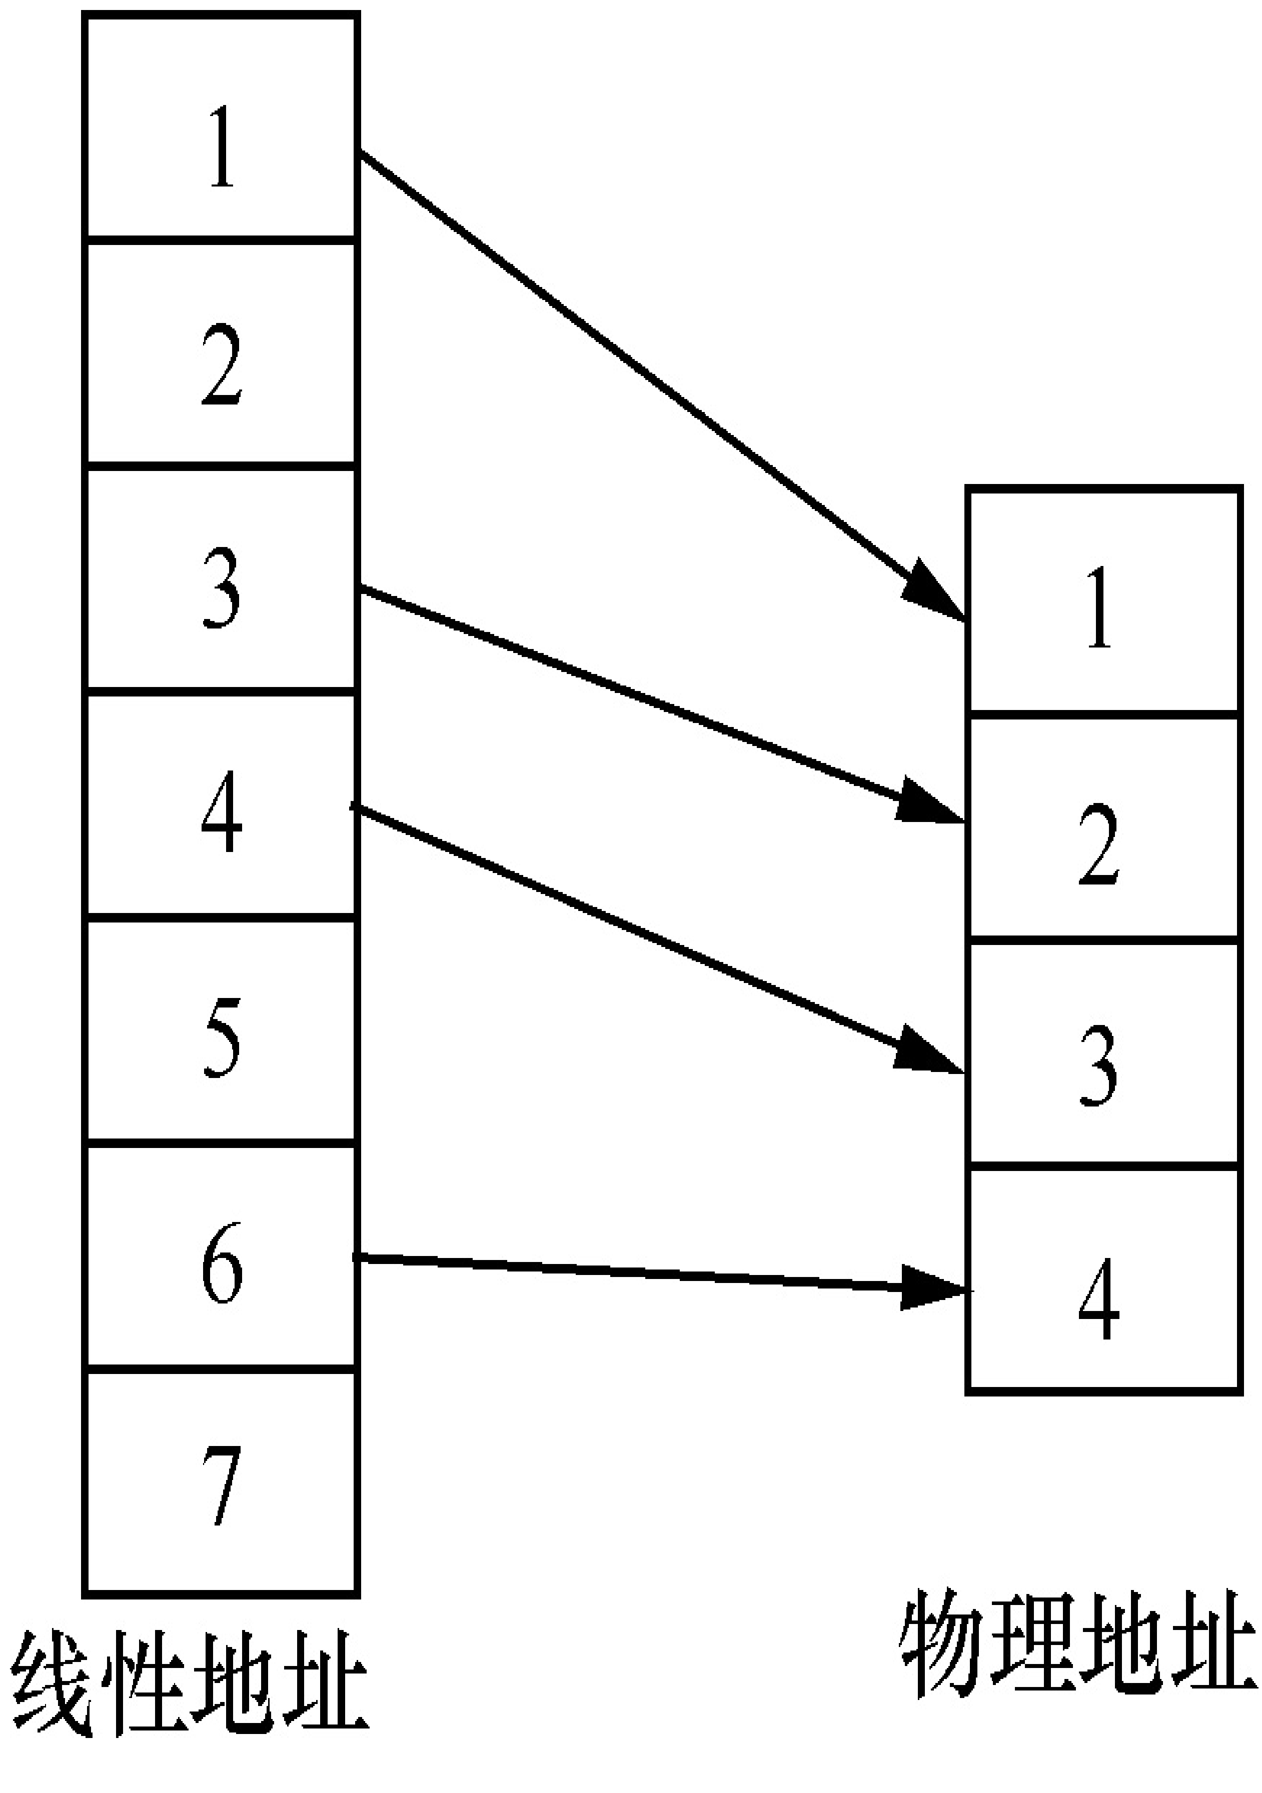
1
2
3
4
5
6
7
线性地址
1
2
3
4
物理地址

▲图4-13　线性地址到物理地址的转换实例

当系统开启了分页机制后，线性地址也需要经过一次转换才是物理地址。为了便于大家理解这个转换过程，举个实例如图4-13所示。

在这个例子中，有两个概念需要先说明一下。

- 页

与分段机制不同的是，分页机制的操作对象是固定大小的内存块，称为“页”。一般情况下，页的大小为4KB。

- 页框

与页的概念相对应，页框是对物理内存的最小操作单位。显然，页和页框的大小必须完全一致，即4KB。

如图4-13所示，线性地址中的1、3、4、6页分别对应物理内存中的1、2、3、4页框。这就意味着，如果一个线性地址刚好落在页3的范围中（线性地址是由页基址和偏移地址组成的，即线性地址=页基址+页内偏移量），那么它对应的物理内存地址在页框2中（即物理地址=页框2基址+页内偏移量）。

当前与物理内存没有映射关系的页（比如2、5、7页），说明它们并不在内存中，因此访问时会产生一个缺页中断。此时操作系统会自动介入处理，利用一定的算法将当前不常用的页调出内存，从而为“缺失页”腾出位置，然后将“缺失页”从外存储器重新取回，最后返回中断点继续操作。由于这些操作对访问者都是透明的，它们并不会感觉到“缺页”事件，从而保证了上层程序的稳定运行。

当然，实际的内核分页机制比这个例子要复杂得多，不过我们暂时只要掌握基础原理即可。有兴趣的读者可以在此基础上深入分析Kernel的具体实现。

本小节主要通过讲解3种类型的地址（逻辑地址、线性地址、物理地址），为读者完整地还原了操作系统虚拟地址的概念与转换原理。相信大家会在后续Android各子系统的学习中受益匪浅。

4.6.2　内存保护（Memory Protection）

最初的操作系统中，并没有严格意义的内存保护机制。对于内存的访问约束完全基于程序编写人员的自觉性——这种做法显然是不可靠的。一方面，没有任何软件程序是十全十美的，它们或多或少都存在Bug，如内存越界；另一方面，那些“不怀好意”的程序可以很容易地攻击和破坏系统中的数据。

人们逐渐认识到内存保护的必要性，并将其列入内存管理的重点。当然，保护方法也越来越多、越来越全面，如上一小节所提到的分段和页式管理。因为每个进程的逻辑地址和物理地址都不是直接对应的，任何进程都没有办法访问到它管辖范围外的内存空间——即便刻意产生的内存越界与非法访问，操作系统也会马上阻止并强行关闭程序，从而有力地保障应用程序和操作系统的安全和稳定。

4.6.3　内存分配与回收

对应用程序而言，内存的分配和回收是它们最关心的。换句话说，这是程序开发者与操作系统内存管理模块间的直接交互点，如图4-14所示。

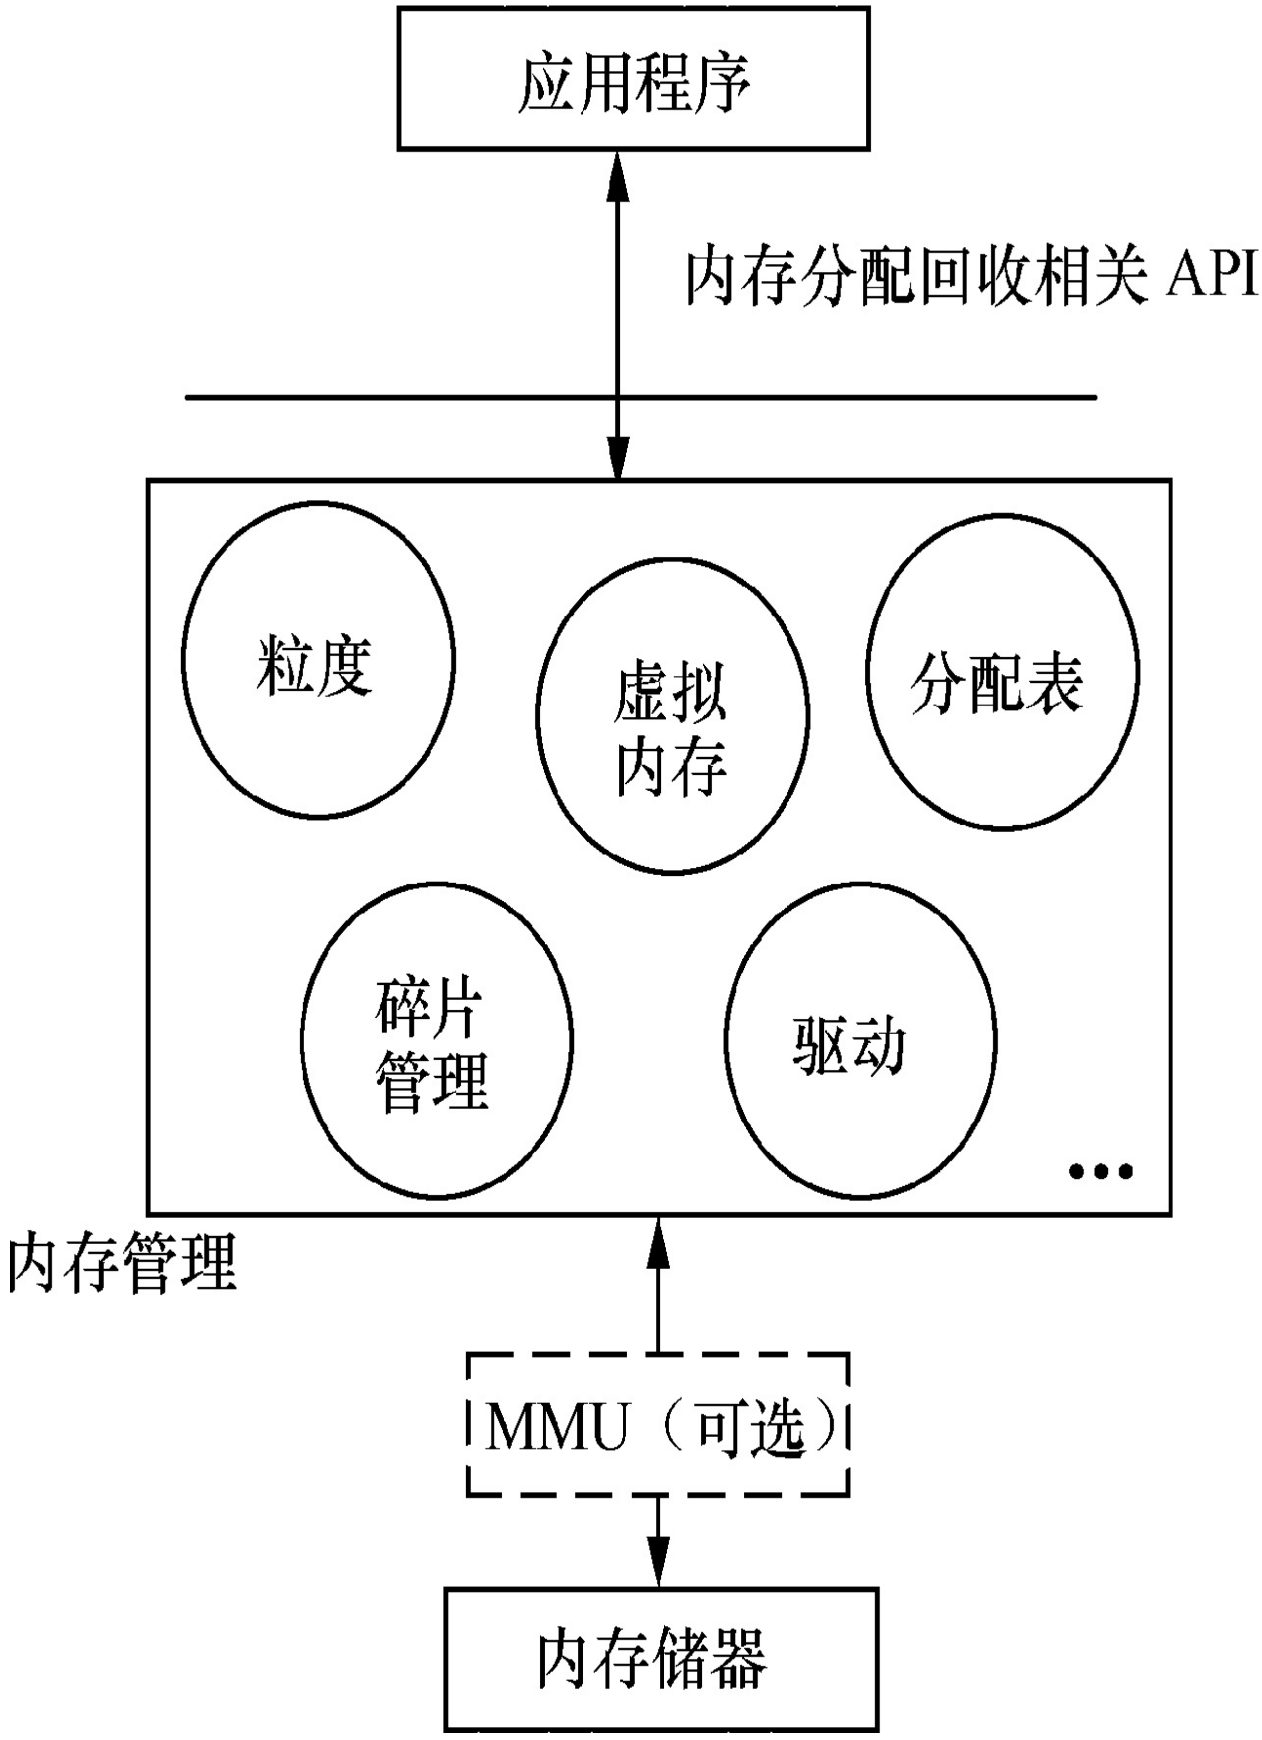

应用程序
内存分配回收相关 API
粒度
虚拟内存
分配表
碎片管理
驱动
…
内存管理
MMU（可选）
内存储器

▲图4-14　内存管理与上层程序

既然是操作系统的重要组成部分，内存管理模块也同样遵循操作系统的定义，即为“上层建筑”控制和使用硬件（内存储器）提供有效的接口方法。Linux Kernel所面对的核心问题包括但不限于：

1．保证硬件无关性

每个硬件平台的物理内存型号、大小甚至架构（比如不同的体系结构）等都可能是不一样的。这种差异绝不能体现在应用程序上，操作系统应尽可能实现向上的“透明”。

2．动态分配内存和回收

需要考虑的问题很多，如如何为内存划分不同的使用区域；分配的粒度问题，即分配的最小单位；如何管理和区别已经使用和未使用的内存；如何回收和再利用等。

3．内存碎片

和磁盘管理一样，内存也一样会有碎片的问题。

举个简单的例子，如图4-15所示。

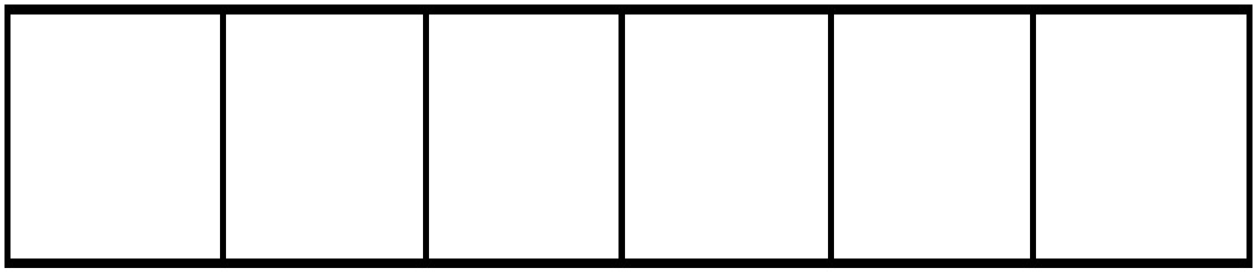

(a) 6 个未使用的内存块

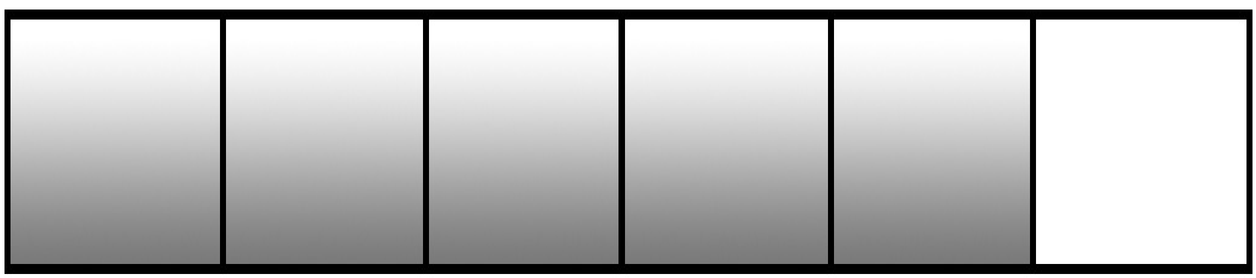

(b) 分配使用了 5 个内存块以后

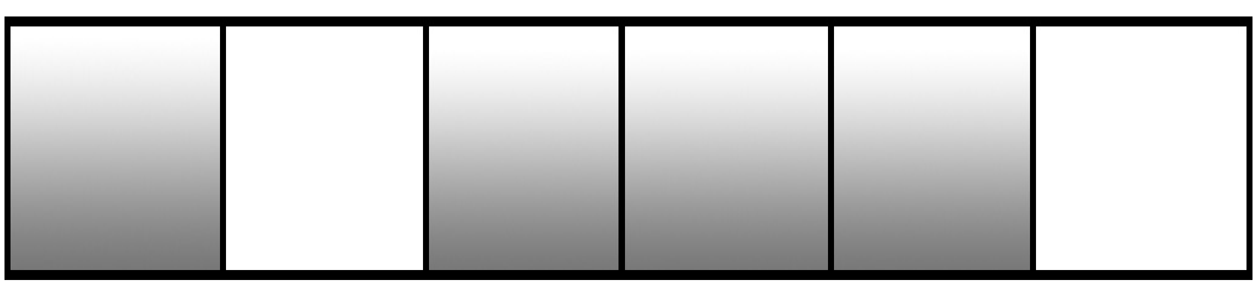

(c) 释放了 1 个内存块以后

▲图4-15　内存碎片实例

在这个例子中，假设初始状态有6块未使用的内存单元。随着程序不断地申请使用，前面5块已经成功分配。此时若某程序释放了第2块单元，那么最后将会有两块不连续的未使用内存单元存在——碎片形成。

另外，内核既要保证内存分配的合理性，也要考虑整体机制的高效性。内存的分配和回收是非常频繁的，如果没有办法实现高效管理，将会极大地影响系统的稳定性。

在Android系统中，内存的分配与回收分为两个方向。

- Native层

本地层的程序基本上是由C/C++编写的，与开发人员直接相关的内存函数包括malloc/free，new/delete等。由于动态分配的内存需要人工管理，根据项目的开发经验——当工程达到一定数量级（特别是像操作系统这样的大工程）时，很容易出现各种问题，如野指针、空指针。我们将在本书的智能指针章节详细总结常见的一些内存致命Bug，并分析它们出现的原因；同时，通过对智能指针实现原理的分析来向读者阐述Google作为Android系统的缔造者又是如何有效避免这些让无数开发者头疼的问题的。

- Java层

大多数Android的应用程序都由Java语言编写。Java相对于C在内存管理上做了很多努力，可以帮助开发人员在一定程度上摆脱内存的各种困扰。但是，Java本身并不是万能的，需要研发者在程序设计过程中保持良好的内存使用规范，并对Android提供的内存管理机制有比较深入的理解。本书后续的章节将在分析系统原理的基础上进一步去理解上层应用的实现，希望可以为读者开发应用程序提供一些帮助。

4.6.4　进程间通信——mmap

本节末尾顺便讲解一下mmap函数，它是兼容POSIX协议的一个系统调用。Linux Kernel和Android系统中都频繁使用到了这个函数。比如上层应用在使用Binder驱动前，就必须通过mmap()来为其正常工作提供

环境。

正如其名所示（Memory Map），mmap可以将某个设备或者文件映射到应用进程的内存空间中，这样访问这块内存就相当于对设备/文件进行读写，而不需要再通过read()，write()了。由此可见，理论上mmap也可以用于进程间通信，即通过映射同一块物理内存来共享内存。这种方式因为减少了数据复制的次数，在一定程度上能提高进程间通信的效率。

我们通过图4-16来加深对mmap()的理解。

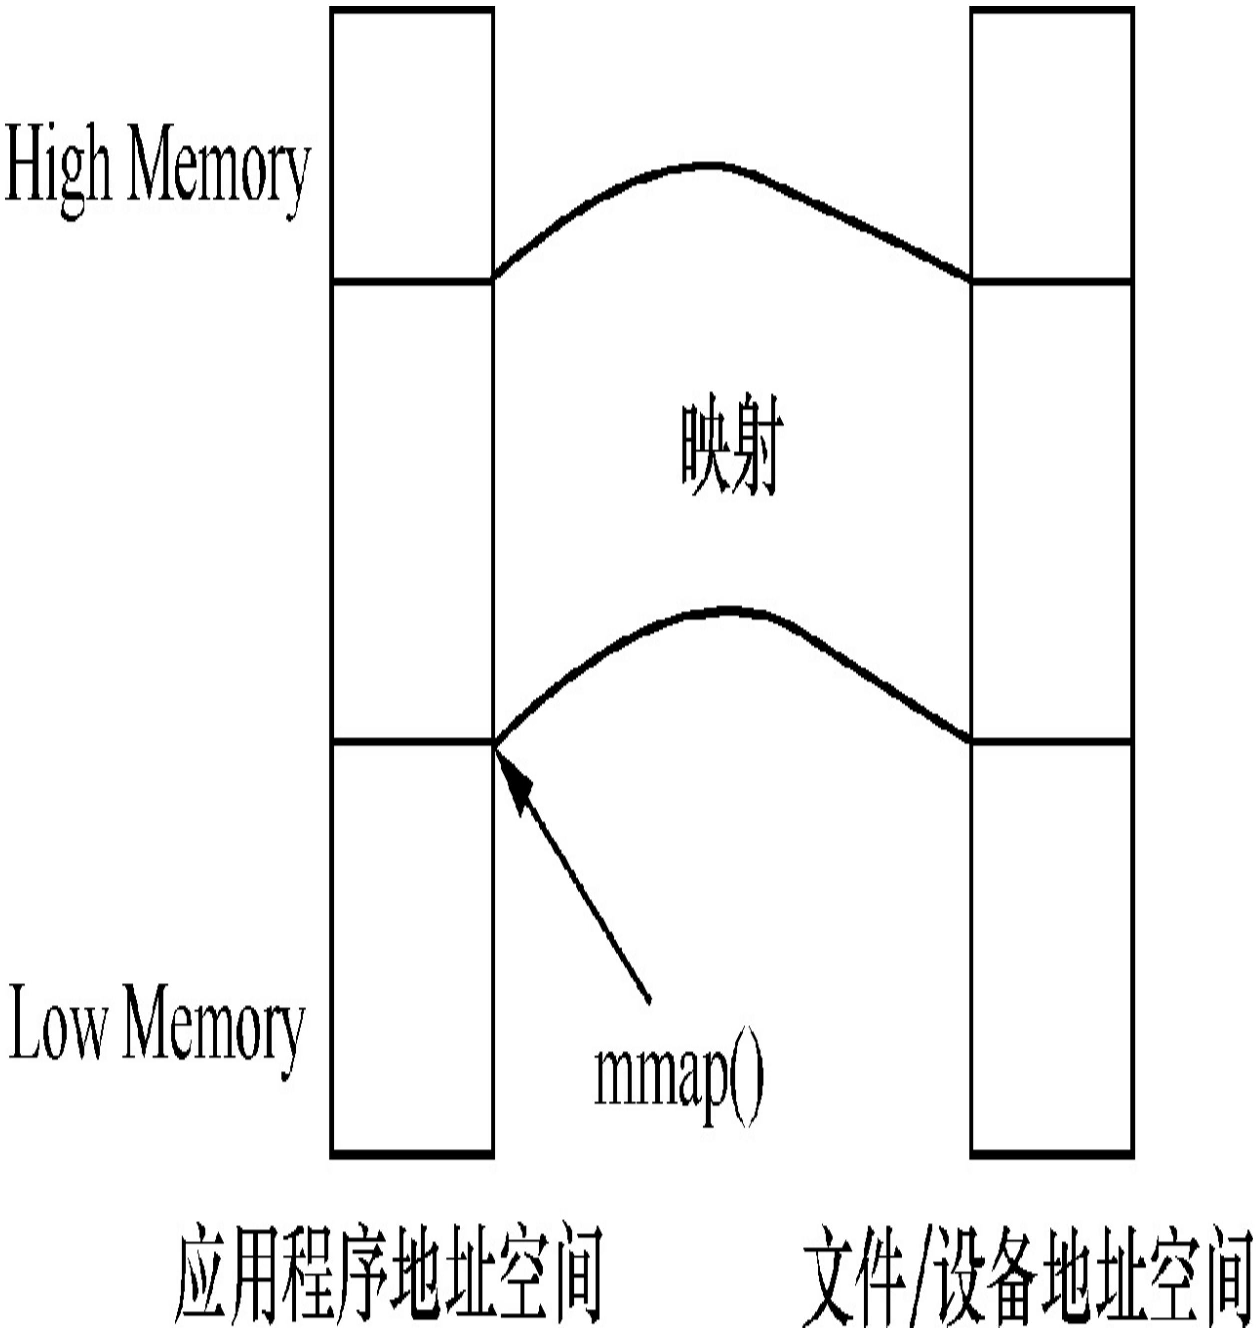

▲图4-16　mmap()示意图

这个函数提供了不少参数选项供用户使用。其函数原型为：

```
void *mmap(void *addr, size_t len, int prot, int flags, int fd, o
```

我们来看看几个参数的具体含义。

- addr

指出文件/设备应该被映射到进程空间的哪个起始地址。这个参数如果为空，则由内核驱动自行决定被映射的地址。

- len

指出被映射到进程空间中内存块的大小。

- prot

指定了被映射内存的访问权限，常用的有如下几种。

- PROT_READ：内存页可读。
- PROT_WRITE：内存页可写。
- PROT_EXEC：内存页是可执行的。
- PROT_SEM：内存页可用于atomic操作。
- PROT_NONE：内存页不可访问。
- flags

指定了程序对内存块所做改变将造成的影响，常用的有如下几种。

- MAP_SHARED：对内存块的修改将被保存到文件中。
- MAP_PRIVATE：对内存块的修改是private的，即只在局部范围内有效。
- MAP_FIXED：使用指定的映射起始地址。
- MAP_ANONYMOUS：匿名映射，也就是说可以不和任何文件进行关联，同时将fd参数设为-1。这是一种比较特殊的映射方式，通常需要进程间有一定关系才能实现。

- fd

  被映射到进程空间的文件的描述符，通常是由open()返回的。

- offset

  指定了从文件的哪一部分开始映射，一般设为0。

- 返回值

  这个函数的返回值分为两类：成功时为0，否则就是错误码。

理解了mmap的使用方法后，读者可以结合本书的Binder章节来综合分析它在内核中的实现原理，并从中进一步巩固本小节所学习的虚拟内存等概念。

这样我们就完整分析了一个典型操作系统所应具有的内存管理的核心功能。可以看出，内存管理所涉及的内容不仅非常多，而且很繁杂——这也是Android基于Linux的好处之一。Linux Kernel的内存管理机制是“有口皆碑”的；而且经过这么多年的验证，已经相当稳定成熟。因此Android完全可以“站在巨人的肩膀上”，去完成更多有意义的事情。比如下一小节将讲解的Low Memory Killer，就是Android在“巨人肩膀上”建立的“低内存处理机制”。

4.6.5 写时拷贝技术（Copy on Write）

COW（Copy on Write）是Linux中一个非常关键的技术。它的基本思想用一句话来概括，就是多个对象在起始时共享某些资源（如代码段、数据段），直到某个对象需要修改该资源时才拥有自己的一份拷贝。从这个描述不难发现，COW完全可以被用到虚拟内存管理之外的其他地方——只要它符合COW的预设场景。

当我们调用fork()函数生成一个子进程时，内核并没有马上为这个“另立门户”的孩子分配自己的物理内存，而是仍然共享父进程的固有资源。这样一来“分家”过程就非常快了——理论上只需要注册一个“门户”就可以了。而如果新进程对现有资源“不是很满意”，希望自己去做些修改，那么此时才需要为它提供自己的“施展空间”。特别是如果子进程在fork()之后很快地调用了exec（概率很大），从而载入

与父进程迥异的映像，那么COW的存在显然可以较大程度地避免不必要的资源操作，从而提升了运行速度。

4.7 Android中的Low Memory Killer

嵌入式设备的一个普遍特点是内存容量相对有限。当运行的程序超过一定数量，或者涉及复杂的计算时，很可能出现内存不足，进而导致系统卡顿的现象。Android系统也不例外，它同样面临着设备物理内存短缺的困境。另外，细心的开发者应该已经注意到了，对于已经启动过一次的Android程序，再一次启动所花的时间明显减少了。原因就在于Android系统并不马上清理那些已经“淡出视野”的程序（比如调用Activity.finish退出UI界面）。换句话说，它们在一定的时间里仍然驻留在内存中（虽然用户已经感觉不到它们的存在）。这样做的好处是明显的，即下一次启动不需要再为程序重新创建一个进程；坏处也同样存在，那就是加大了内存OOM（Out Of Memory）的概率。

那么，应该如何掌握平衡点呢？

熟悉Linux的开发人员应该知道，底层内核有自己的内存监控机制，即OOMKiller。一旦发现系统的可用内存达到临界值，这个OOM的管理者就会自动跳出来“收拾残局”。根据策略的不同，OOM的处理手段略有差异。不过它的核心思想始终是：

按照优先级顺序，从低到高逐步杀掉进程，回收内存。

优先级的设定策略一方面要考虑对系统的损害程度（例如系统的核心进程，优先级通常较高），另一方面也希望尽可能多地释放无用内存。根据经验，一个合理的策略至少要综合以下几个因素：

- 进程消耗的内存；
- 进程占用的CPU时间；
- oom_adj（OOM权重）。

我们先来了解下Linux Kernel中的OOM Killer。内核所管理的进程都有一个衡量其oom权重的值，存储在/proc/<PID>/oom_adj中。根据这一权重值以及上面所提及的若干其他因素，系统会实时给每个进程评分，以决定OOM时应该杀死哪些进程。比如oom_score分数越低的进程，被杀死的概率越小，或者说被杀死的时间越晚。

这个值存储在/proc/<PID>/oom_score中。下面所示分别是PID为427和415的两个进程的oom数值。

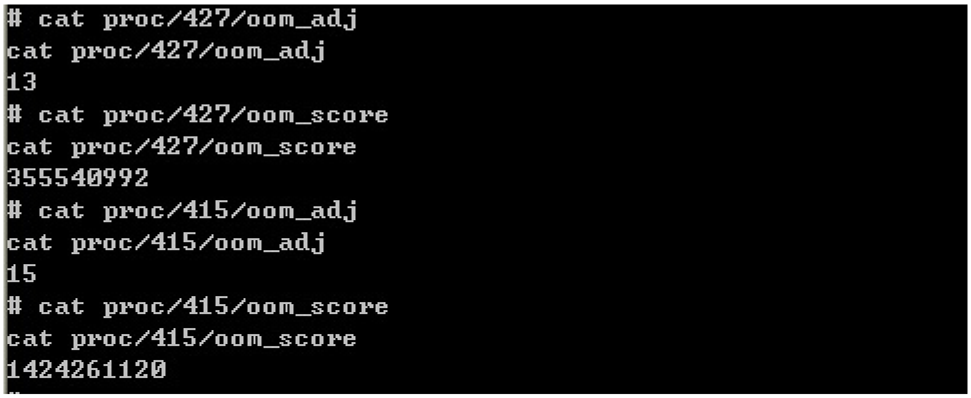

基于Linux内核OOM Killer的核心思想，Android系统扩展出了自己的内存监控体系。因为Linux下的“内存杀手”要等到系统资源“濒临绝境”的情况下才会产生效果，而Android则实现了“不同梯级”的Killer。

Android系统为此开发了一个专门的驱动，名为Low Memory Killer（LMK）。源码路径在内核工程的drivers/staging/android/Lowmemorykiller.c中。先来看看它的驱动加载函数：

```
static int __init lowmem_init(void)
{
     task_free_register(&task_nb);
     register_shrinker(&lowmem_shrinker);
     return 0;
}
module_init(lowmem_init);
```

可见LMK向内核线程kswapd注册了一个shrinker的监听回调，实现体为lowmem_shrinker。当系统的空闲页面低于一定阈值时，这个回调就会被执行。

Lowmemorykiller.c中定义了两个数组，分别如下：

```
static int lowmem_adj[6] = {
     0,
     1,
     6,
```

```
    12,
};
static int lowmem_adj_size = 4; //下面的数值以此为单位（页大小）
static size_t lowmem_minfree[6] = {
    3 * 512,   /* 6MB */
    2 * 1024,  /* 8MB */
    4 * 1024,  /* 16MB */
    16 * 1024, /* 64MB */
};
```

第一个数组lowmem_adj最多有6个元素（默认只定义了4个），它表示可用内存容量处于“某层级”时需要被处理的adj值；第二个数组则是对“层级”的描述。举个例子，lowmem_minfree的第一个元素是3*512，即3*512*lowmem_adj_size=6MB。也就是说，当可用内存小于6MB时，Killer需要清理adj值为0（即lowmem_adj的第一个元素）以下的那些进程。其中adj的取值范围是17～15，数字越小表示进程级别越高（通常只有0～15被使用）。

LMK的实现如图4-17所示。

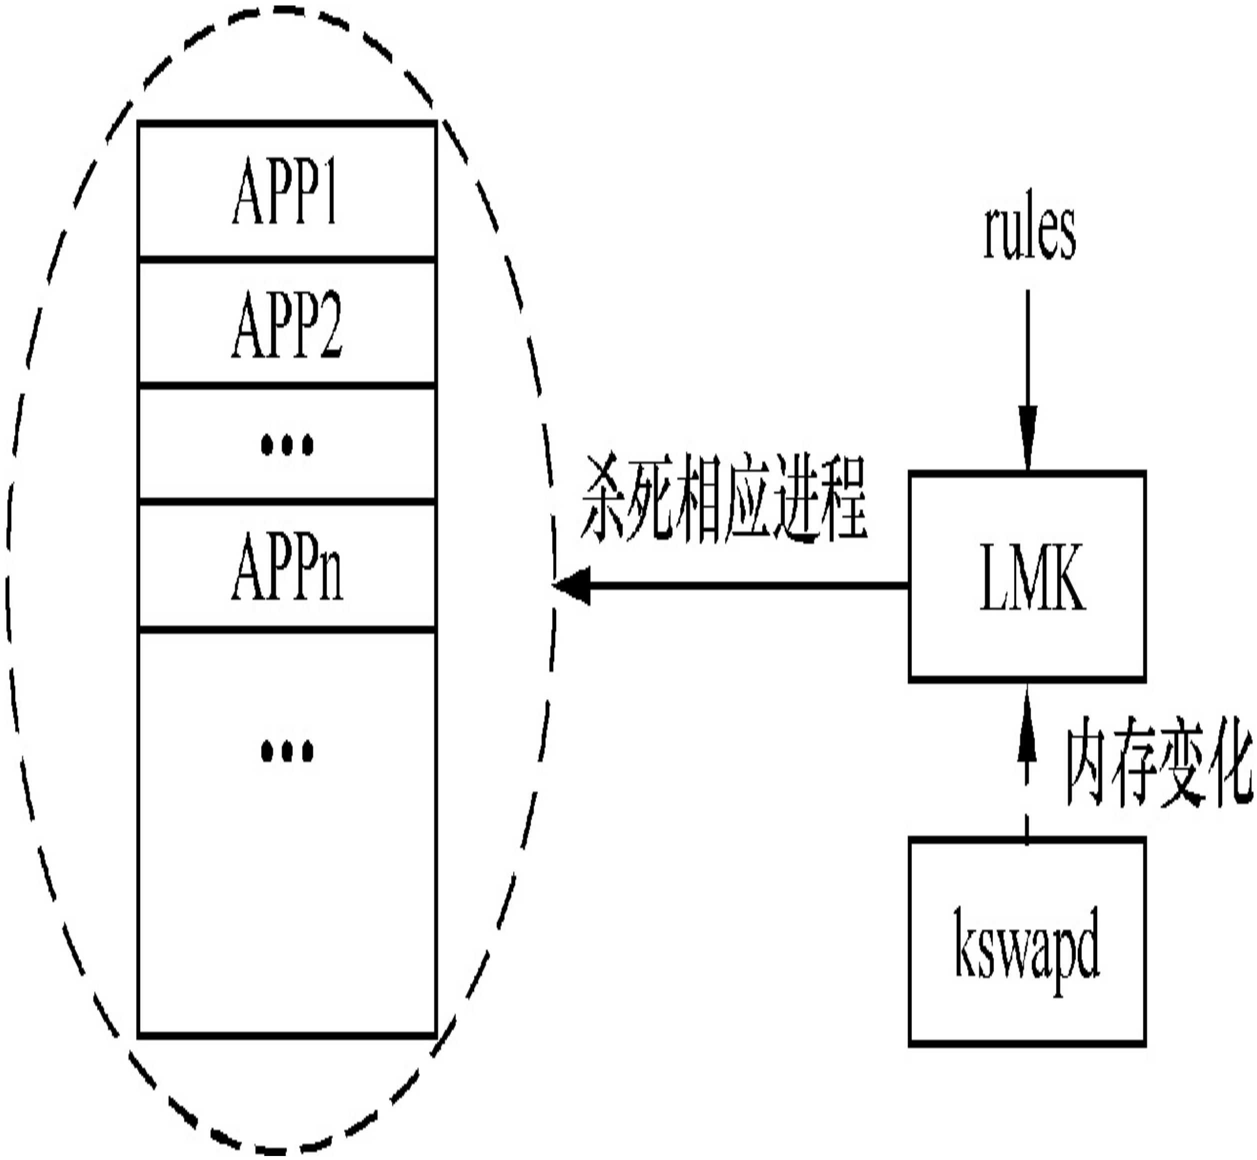

▲图4-17　LMK的实现简图

值得一提的是，这两个数组（lowmem_adj和lowmem_adj_size）只是系统的预定义值，我们还可以根据项目的实际需求来做定制。Android系统提供了相应的文件来供我们修改这两组值。路径如下：

```
/sys/module/lowmemorykiller/parameters/adj
/sys/module/lowmemorykiller/parameters/minfree
```

比如，可以在init.rc（系统启动时由init进程解析的一个脚本，参见后续章节）中加入这样的语句：

```
write /sys/module/lowmemorykiller/parameters/adj      0,8
write  /sys/module/lowmemorykiller/parameters/minfree1024,4096
```

ActivityManagerService中有一个名为updateOomLevels的函数，其内部实现原理也是通过写上面这两个文件来实现的。此外，AMS在运行时还会根据系统的当前配置自动修正adj和minfree，以尽可能适配不同的硬件。具体如下所示：

```
# cat /sys/module/lowmemorykiller/parameters/adj
cat /sys/module/lowmemorykiller/parameters/adj
0,1,2,4,9,15
# cat /sys/module/lowmemorykiller/parameters/minfree
cat /sys/module/lowmemorykiller/parameters/minfree
5181,6727,8273,10321,11868,14458
```

讨论完LMK所采用的“rules”后，我们再来从程序进程的角度进行分析。显然，当LMK执行清理工作时，它需要知道当前系统中所有进程的adj归属情况。换句话说，即系统如何给进程评定adj等级。

默认情况下，Android会将所有进程划归为如表4-5所示的若干种adj。

表4-5　Android进程所属ADJ值

ADJ	Description
HIDDEN_APP_MAX_AD= 15	当前只运行了不可见的Activity组件的进程
HIDDEN_APP_MIN_ADJ = 9	
SERVICE_B_ADJ = 8	B list of Service。和A list相比，它们对用户的黏合度要小一些
PREVIOUS_APP_ADJ = 7	用户前一次交互的进程。按照用户的使用习惯，人们经常会在几个常用进程间切换，所以这类进程得到再次运行的概率比较大
HOME_APP_ADJ = 6	Launcher进程，它对于用户的重要性不言而喻
SERVICE_ADJ = 5	当前运行了application service的进程
BACKUP_APP_ADJ = 4	用于承载backup相关操作的进程

HEAVY_WEIGHT_APP_ADJ=3	重量级应用程序进程
PERCEPTIBLE_APP_ADJ = 2	这类进程能被用户感觉到但不可见，如后台运行的音乐播放器
VISIBLE_APP_ADJ = 1	有前台可见的Activity的进程，如果轻易杀死这类进程将严重影响用户的体验
FOREGROUND_APP_ADJ = 0	当前正在前台运行的进程，也就是用户正在交互的那个程序
PERSISTENT_PROC_ADJ = -12	Persistent性质的进程，如telephony
SYSTEM_ADJ = -16	系统进程

除了表4-5所示的系统的评定标准，我们有没有办法自己来改变进程的adj（在Android中，被称为oom_adj）值呢？

答案是肯定的且方法不是唯一的。

1．写文件

和前面的adj和minfree类似，进程的oom_adj也可以通过写文件的形式来修改，路径为/proc/<PID>/oom_adj。比如init.rc中就有如下语句：

```
on early-init
   write /proc/1/oom_adj-16
```

PID值为1的进程是init程序，这里将此进程的adj改为16，以保证它不会被杀死。

2．android:persistent

对于某些非常重要的应用程序，我们不希望它们被系统杀死。一个最简单的方法就是在它的AndroidManifest.xml文件中给“application”标签添加“android:persistent=true”属性。不过将应用程序设置为常驻内存要特别慎重，如果应用程序本身不够完善，而系统又不能通过正常方式回收它的话，则有可能导致意想不到的问

题。

4.8 Android匿名共享内存（Anonymous Shared Memory）

Anonymous Shared Memory（简称Ashmem）是Android特有的内存共享机制，它可以将指定的物理内存分别映射到各个进程自己的虚拟地址空间中，从而便捷地实现进程间的内存共享。不过其本质还是没有超出前面小节介绍的基础知识，只能算是对以上经典理论的应用与改进。

4.8.1 Ashmem设备

Ashmem的实现依托于/dev/ashmem设备，其源码数量很少，核心文件在Linux工程中：

```
/common/mm/ashmem.c
/common/include/linux/ashmem.h
```

这两个文件都不长，我们主要关心ashmem设备的以下几个问题：

- 设备节点是什么时候创建的；
- 设备对应的操作函数有哪些，如open、mmap、ioctl等，以及它们的实现原理；
- 它与linux中的内存共享机制的区别与联系。

当Android系统启动时，init程序会读取init.rc文件进行解析。ueventd就是这时启动的，如下：

```
on early-init
     …
    start ueventd
```

进程ueventd对应的源码在/system/core/init/Ueventd.c中，来看看它的main函数实现。

```
int ueventd_main(int argc, char **argv)
{
    struct pollfd ufd;
    int nr;
    char tmp[32];
    …
    ueventd_parse_config_file("/ueventd.rc");
```

```
    snprintf(tmp, sizeof(tmp), "/ueventd.%s.rc", hardware);
    ueventd_parse_config_file(tmp);
    …
```

可见，默认情况下ueventd会去解析ueventd. rc和ueventd. <hardware>. rc文件来加载指定的设备。以ueventd. rc为例，它的格式大概如下：

```
/dev/null                 0666   root       root
/dev/zero                 0666   root       root
/dev/full                 0666   root       root
/dev/ptmx                 0666   root       root
/dev/tty                  0666   root       root
/dev/random               0666   root       root
/dev/urandom              0666   root       root
/dev/ashmem               0666   root       root
/dev/binder               0666   root       root
```

包括binder，ashmem在内的一系列设备节点信息都会在这里被读取到系统中（不过此时未必马上创建节点）。具体细节大家可以自行深入分析，我们这里的重点是ashmem设备相关的处理流程。先从ashmem的init入口来看看它是什么类型的设备：

```
/*ashmem.c*/
static int __init ashmem_init(void)
{
     int ret;
     ashmem_area_cachep = kmem_cache_create("ashmem_area_cache",
                           sizeof(struct ashmem_area), 0, 0, NULL
     …
     ashmem_range_cachep = kmem_cache_create("ashmem_range_cache"
                           sizeof(struct ashmem_range), 0, 0, NUL
     …
     ret = misc_register(&ashmem_misc);
     …
     return 0;
}
```

很明显，ashmem是一个misc设备（主设备号10），所以它使用misc_register进行注册。设备的描述如下：

```
static struct miscdevice ashmem_misc = {
     .minor = MISC_DYNAMIC_MINOR,
     .name = "ashmem",
```

```
    .fops = &ashmem_fops,
};
```

其实现了如下所示的文件操作接口：

```
static struct file_operations ashmem_fops = {
    .owner = THIS_MODULE,
    .open = ashmem_open,
    .release = ashmem_release,
    .read = ashmem_read,
    .llseek = ashmem_llseek,
    .mmap = ashmem_mmap,
    .unlocked_ioctl = ashmem_ioctl,
    .compat_ioctl = ashmem_ioctl,
};
```

全局变量ashmem_area_cachep和ashmem_range_cachep是通过kmem_cache_create()创建的kmem_cache对象。其中第一个函数参数是这个cache的名称，第二个参数是cache大小，随后的参数分别表示对齐方式、标志以及构造函数。

我们知道，Linux内核在内存管理上有Slab、Slub和Slob三种机制。Slab是在2.6.23版本以前内核所采用的默认分配手段，之后则以Slub来代替。Slob则是更适合嵌入式系统的一种内存管理机制。这里面涉及很多内核实现细节，大家若有兴趣可以参阅相关资料。这里我们只要明白内核提供了一整套高效的内存分配和回收机制即可。

这两个cache是ashmem后续一系列操作的基础，进程间的匿名共享内存将从这里分配。

接下来，我们依次分析ashmem_open、ashmem_mmap和ashmem_ioctl。

1．ashmem_open

```
static int ashmem_open(struct inode *inode, struct file *file)
{
    struct ashmem_area *asma;
    int ret;
    …
    asma = kmem_cache_zalloc(ashmem_area_cachep, GFP_KERNEL);
    …
```

```
    INIT_LIST_HEAD(&asma->unpinned_list);
    memcpy(asma->name, ASHMEM_NAME_PREFIX, ASHMEM_NAME_PREFIX_LE
    asma->prot_mask = PROT_MASK;
    file->private_data = asma;
    return 0;
}
```

可以看到open主要做了两个工作，首先是从ashmem_area_cachep分配一块ashmem_area内存，然后对这块共享内存做了一些初始化操作，包括名称、权限等，并把它记录在file->private_data中。这样，后续就可以通过file来访问到这块共享内存了。

2．ashmem_mmap

```
static int ashmem_mmap(struct file *file, struct vm_area_struct *
{
    struct ashmem_area *asma = file->private_data;/*取出上一步保存!
    int ret = 0;

    mutex_lock(&ashmem_mutex);//互斥锁

    /* 在做mmap前，一定要先通过ioctl设置大小，我们后面还会讲到 */
    if (unlikely(!asma->size)) {
        ret = -EINVAL;
        goto out;
    }

    /* 所请求的权限保护必须与我们给asma分配的权限相匹配 */
    if (unlikely((vma->vm_flags & ~calc_vm_prot_bits(asma->prot_
                         calc_vm_prot_bits(PROT_MASK))) {
        ret = -EPERM;
        goto out;
    }
    …
    if (!asma->file) {//当前还没创建backing file
        char *name = ASHMEM_NAME_DEF;
        struct file *vmfile;
        if (asma->name[ASHMEM_NAME_PREFIX_LEN] != '\0')
            name = asma->name;

        /* 创建ashmem的临时支持文件 */
        vmfile = shmem_file_setup(name, asma->size, vma->vm_fla
        …
        asma->file = vmfile;
    }
    get_file(asma->file);
```

```
    if (vma->vm_flags & VM_SHARED)
        shmem_set_file(vma, asma->file); //内存映射
    else {
        if (vma->vm_file)
            fput(vma->vm_file);
        vma->vm_file = asma->file;
    }
    vma->vm_flags |= VM_CAN_NONLINEAR;

out:
    mutex_unlock(&ashmem_mutex);
    return ret;
}
```

在Linux系统中，mmap可以把一个文件（这里指/dev/ashmem设备文件）映射到进程虚拟空间中，从而使得程序可以像使用内存一样去操作文件。前一小节我们已经专门讲解过mmap的使用方法了，此处不再赘述。

对于ashmem_mmap有两点疑问：

- /dev/ashmem这个文件中的内存空间从何而来？
- 使用ashmem的进程很多，共享内存的双方是如何建立关联的？假设有两对希望通过ashmem来实现匿名内存共享的进程（P11/P12和P21/P22），那么ashmem是如何正确区分它们的呢？

在上面这个函数中，首先通过private_data取得这个进程的asma，它是在ashmem_open时创建的。在取得互斥锁后，还需要检查asma->size是否合法，这个大小值是通过后面要讲到的ioctl设置的。如果asma->file为空，说明这是第一个访问该共享空间的进程。可以看到，其中最关键的就是shmem_file_setup函数。这个函数是Linux提供的，目的就是在tmpfs中创建一个临时文件，用于进程间的内存共享。由此可见，Android的ashmem实际上是借用并扩展了Linux Kernel的内存共享机制。

再来看第二个疑问。可以先猜想下，即使用ashmem来共享，内存的双方应该拥有一个共同的tmpfs中的临时文件（即asma->file）。理由如下：

当asma->file为空时，ashmem会为这个进程创建临时文件，并把它记录在asma->file中，这可以看作P11或P21的工作。而后P12或者P22执行mmap时，假如asma->file不为空呢？此时自然不会再创建一个tmpfs临时文件，而是直接调用shmem_set_file做好内存映射。换句话说，只要P11/P21与P12/P22拥有同一个tmpfs临时文件的fd描述符，则第二个问题就迎刃而解了。

下一小节我们将专门分析Android系统中的一个实例来证明上述猜测，如图4-18所示。

3．ashmem_ioctl

在ashmem_mmap的开头，程序需要判断asma->size的合法性，这是ashmem_ioctl

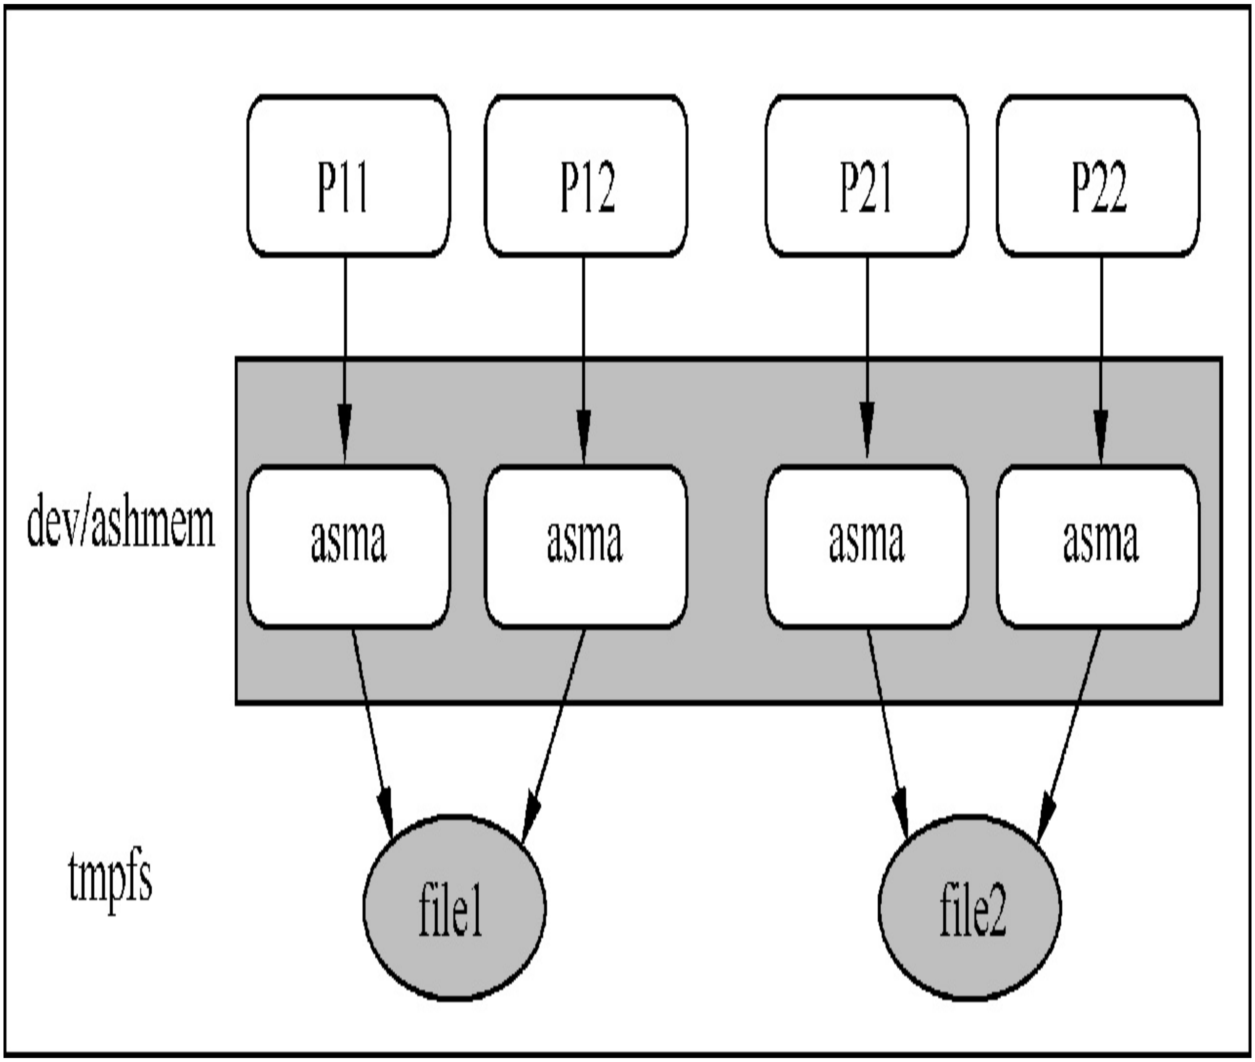

▲图4-18　ashmem中的内存共享示意图

提供的诸多功能之一：

```
static long ashmem_ioctl(struct file *file, unsigned int cmd, uns
{
     struct ashmem_area *asma = file->private_data;
     long ret = -ENOTTY;

     switch (cmd) {
     case ASHMEM_SET_NAME://设置名称
          ret = set_name(asma, (void __user *) arg);
          break;
     case ASHMEM_GET_NAME://获取名称
          ret = get_name(asma, (void __user *) arg);
          break;
```

```
    case <strong>ASHMEM_SET_SIZE</strong>://设置大小
        ret = -EINVAL;
        if (!asma->file) {
            ret = 0;
            asma->size = (size_t) arg;
        }
        break;
    …
    }
    return ret;
}
```

这个函数的实现相对简单，即根据ioctl命令来做相应的操作——比如设置和获取size大小、名称等，并将信息保存到各个进程自己的asma中。

4.8.2 Ashmem应用实例

上一小节我们分析了/dev/ashmem设备驱动中3个重要函数的源码实现。Android系统就是基于ashmem设备来实现跨进程内存共享的，如MemoryDealer。

MemoryDealer可以看作对ashmem的封装，源码位于frameworks/native/libs/binder中，可见它与Binder机制有直接关联。MemoryDealer在Android中有不少应用场景，如音频系统中的AudioFlinger就是通过它来与AudioTrack实现跨进程的音频数据传递的。建议读者把本小节的分析范例和音频系统章节结合起来理解，从而一目了然。

先来看AudioFlinger这边的操作：

```
AudioFlinger::Client::Client(const sp<AudioFlinger>& audioFlinger
    :   RefBase(),
        mAudioFlinger(audioFlinger),
        mMemoryDealer(new MemoryDealer(1024*1024, "AudioFlinger::
```

MemoryDealer内部有两个重要的成员变量，即mHeap和mAllocator。从名称上可以看出，mAllocator是一个“内存分配器”，它服务的对象是“内存承载体”——mHeap。举个例子，mHeap就像餐厅座位，而mAllocator则是服务员。当客人有用餐请求时，服务员需要根据具体人数来安排他们。服务员可采用的分配策略多种多样，总的原则

就是尽量满足大部分顾客的需求。

从实现上来看，mHeap是一个MemoryHeapBase对象。构造函数如下：

```
MemoryHeapBase::MemoryHeapBase(size_t size, uint32_t flags, char
{
    const size_t pagesize = getpagesize();
    size = ((size + pagesize-1) & ~(pagesize-1));
    int fd = ashmem_create_region(name == NULL ? "MemoryHeapBase"
    if (fd >= 0) {
        if (mapfd(fd, size) == NO_ERROR) {//空间映射
            …
        }
    }
}
```

变量fd是由ashmem_create_region返回的文件描述符，可想而知它一定是打开/dev/ashmem所产生的。这个函数在system/core/libcutils/Ashmem-host.c和system/core/libcutils/Ashmem-dev.c中都有实现。以“host”结尾的是提供给模拟器的，而以“dev”为后缀的则是为真实设备服务的。我们只看后面文件中的实现：

```
int ashmem_create_region(const char *name, size_t size)
{
     int fd, ret;
     fd = open(ASHMEM_DEVICE, O_RDWR);
     …
     if (name) {
          char buf[ASHMEM_NAME_LEN];
          strlcpy(buf, name, sizeof(buf));
          ret = ioctl(fd, ASHMEM_SET_NAME, buf);//设置名称
          if (ret < 0)
               goto error;
     }
     ret = ioctl(fd, ASHMEM_SET_SIZE, size);//设置大小
     …
}
```

果不其然，首先就打开了ASHMEM_DEVICE="/dev/ashmem"这个设备，然后依次执行ASHMEM_SET_NAME和ASHMEM_SET_SIZE这两个ioctl命令，这也和我们前面的分析吻合。

打开ashmem后，接下来要把设备空间映射到进程中来，也就是mapfd函数实现的功能：

```
status_t MemoryHeapBase::mapfd(int fd, size_t size, uint32_t offs
{
    …
    if ((mFlags & DONT_MAP_LOCALLY) == 0) {
        void* base = (uint8_t*)mmap(0,size,PROT_READ|PROT_WRITE,
        …
        mBase = base;
        mNeedUnmap = true;
    } else  {
        …
    }
    mFD = fd;
    mSize = size;
    mOffset = offset;
    return NO_ERROR;
}
```

MemoryHeapBase内部有一系列成员变量来保存共享内存相关的数据，如mBase就是共享内存映射到进程空间中的内存起点，mFD是ashmem设备相对应的文件描述符，mSize是被映射空间的大小等。

这样ashmem设备就为AudioFlinger开辟了一块共享内存，那么如何让AudioTrack也知道这块内存呢？根据前一小节的猜测，AudioTrack是通过文件描述符fd来与这块共享区建立关联的。那么问题转化为：怎么把fd这个值传给AudioTrack？

大家可能马上会想到Binder机制。没错，确实是通过它来实现的。

AudioTrack先通过getCblk来获得一个IMemory对象：

```
sp<IAudioTrack>track = audioFlinger->createTrack(…);
sp<IMemory> cblk = track->getCblk();
```

其中的track变量是AudioTrack与AudioFlinger的连接通道。按照Binder机制的实现原理，track->getCblk()最终执行的是TrackBase（此时已经在AudioFlinger进程）中的getCblk：

```
sp<IMemory> getCblk() const { return mCblkMemory; }
```

而这个mCblkMemory则是由TrackBase在构造时申请的：

```
mCblkMemory = client->heap()->allocate(size);
```

这里的client->heap就是前面所说的MemoryDealer，它的allocate()函数会返回由MemoryHeap Base申请的内存映射空间：

```
sp<IMemory> MemoryDealer::allocate(size_t size)
{
    sp<IMemory> memory;
    const ssize_t offset = allocator()->allocate(size);
                                 //通过“服务员”来分配“座位”，不过i
                                             //只得到“座位号”
    if (offset >= 0) {
        memory = new Allocation(this, heap(), offset, size);//分配
    }
    return memory;
}
```

按照前面所做的类比，allocator是“服务”员，于是通过它可以安排到“座位”。不过并不是mHeap本身，而是Allocation，我们来分析下原因。

Allocation构造函数：

```
/*frameworks/native/libs/binder/MemoryDealer.cpp*/
Allocation::Allocation(const sp<MemoryDealer>& dealer,
        const sp<IMemoryHeap>& heap, ssize_t offset, size_t size)
    : MemoryBase(heap, offset, size), mDealer(dealer)
{
#ifndef NDEBUG
    void* const start_ptr = (void*)(intptr_t(heap->base()) + offs
    memset(start_ptr, 0xda, size);
#endif
}
```

IMemoryHeap和IMemory是什么关系呢？前者是MemoryHeapBase的父类，后者则是Allocation的父类。这几个类的取名并不是太合理，很容易引起混乱，它们的关系如图4-19所示。

也就是当Allocation构造时，由第二个参数传入的就是IMemoryHeap对象，对应的是前面我们分析过的MemoryHeapBase，这样IMemory和IMemoryHeap就建立了关联。

分析完AudioFlinger（Server）这一侧，我们回到AudioTrack（Client）端。也就是：

```
sp<IMemory> cblk = track->getCblk();
```

我们知道cblk是一个IMemory对象，那么它是BnMemory吗？不是。这是由Binder的实现原理决定的。Server端是BnMemory，那么Client端对应的通常就应该是BpMemory。这些细节我们将在后续的Binder原理章节进行详细解释，这里要记住cblk实际上是一个BpMemory。

cblk此时还没有接触到真正的共享内存——需要由接下来的代码从IMemory中进一步获取：

```
mCblk = static_cast<audio_track_cblk_t*>(cblk->pointer());
```

变量mCblk的数据类型是audio_track_cblk_t。按照我们的猜测，它的内部一定会存储共享内存被映射到AudioTrack进程空间中的虚拟地址（mmap后的结果）。换句话说，cblk->pointer从表面上看很简单，但实际上它要完成：

- 得到AudioFlinger中创建的这块共享内存的地址；
- 将这个地址进一步转化成AudioTrack可以直接访问的虚拟地址。

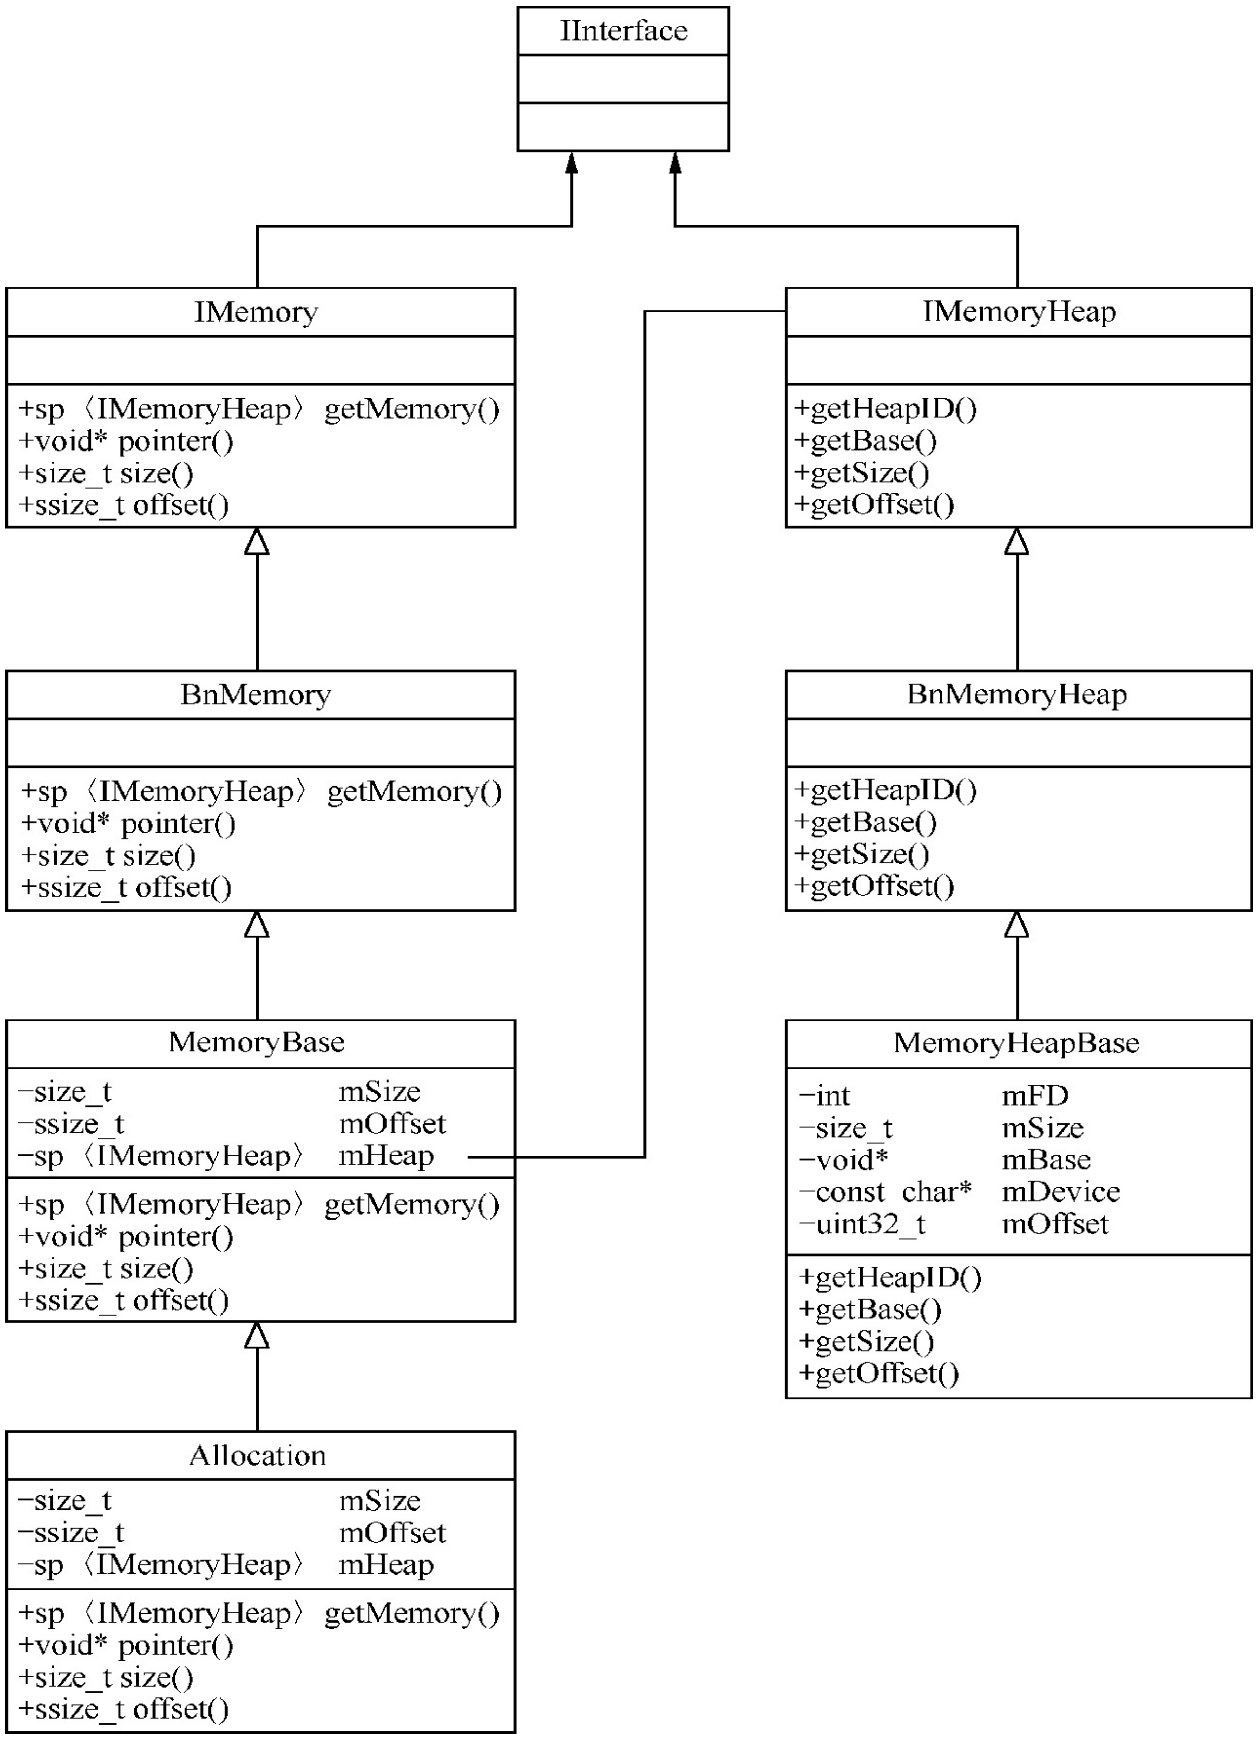
IInterface
IMemory
+sp 〈IMemoryHeap〉 getMemory()
+void* pointer()
+size_t size()
+ssize_t offset()
IMemoryHeap
+getHeapID()
+getBase()
+getSize()
+getOffset()
BnMemory
+sp 〈IMemoryHeap〉 getMemory()
+void* pointer()
+size_t size()
+ssize_t offset()
BnMemoryHeap
+getHeapID()
+getBase()
+getSize()
+getOffset()
MemoryBase
−size_t mSize
−ssize_t mOffset
−sp 〈IMemoryHeap〉 mHeap
+sp 〈IMemoryHeap〉 getMemory()
+void* pointer()
+size_t size()
+ssize_t offset()
MemoryHeapBase
−int mFD
−size_t mSize
−void* mBase
−const char* mDevice
−uint32_t mOffset
+getHeapID()
+getBase()
+getSize()
+getOffset()
Allocation
−size_t mSize
−ssize_t mOffset
−sp 〈IMemoryHeap〉 mHeap
+sp 〈IMemoryHeap〉 getMemory()
+void* pointer()
+size_t size()
+ssize_t offset()

▲图4-19　IMemory和ImemoryHeap的继承关系图

前面说过，两个进程在ashmem中之所以能共享同一内存，是因为它们使用了一样的ashmem文件描述符。这就是cblk->pointer要完成的重点所在。

因为cblk是BpMemory，而BpMemory也继承自IMemory，关系如图4-20所示。

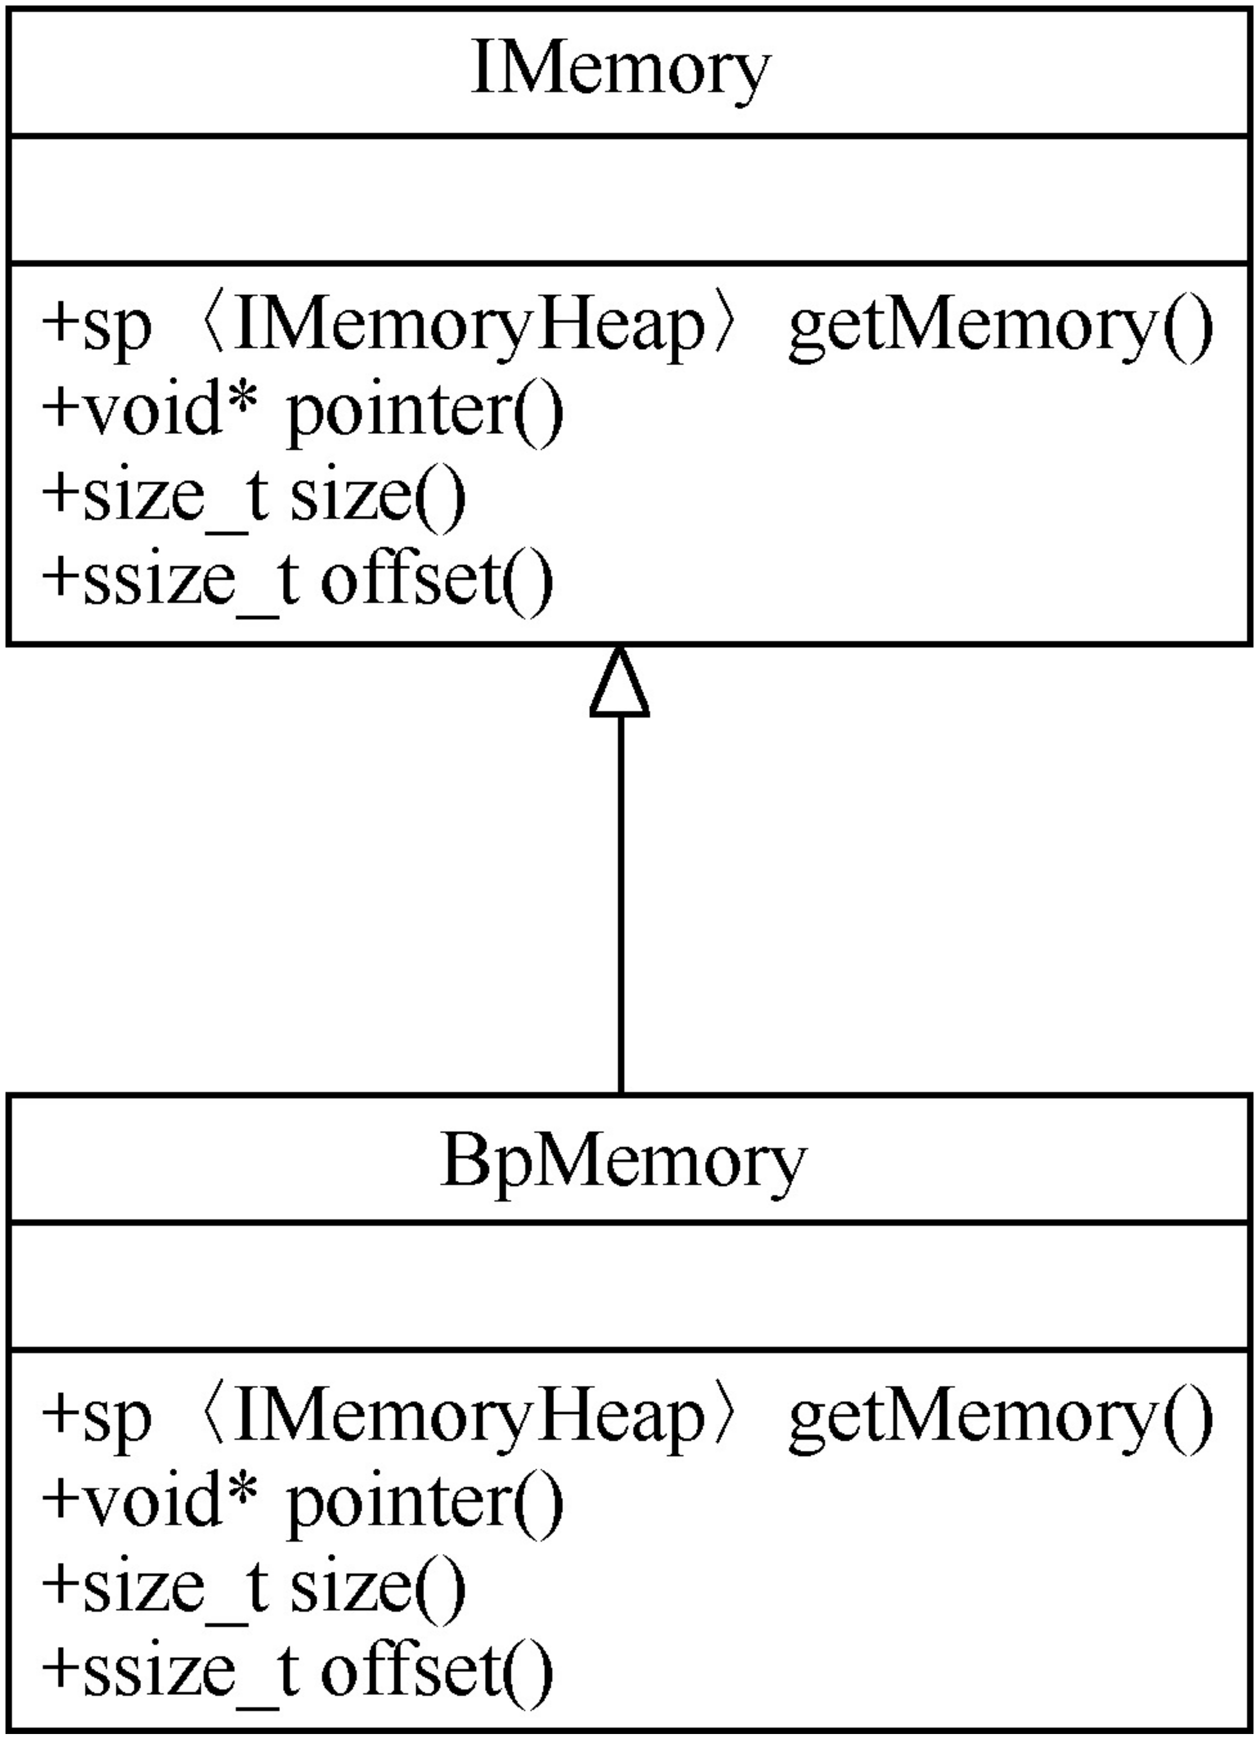
IMemory
+sp 〈IMemoryHeap〉 getMemory()
+void* pointer()
+size_t size()
+ssize_t offset()
BpMemory
+sp 〈IMemoryHeap〉 getMemory()
+void* pointer()
+size_t size()
+ssize_t offset()

▲图4-20　Client端的IMemory

所以cblk->pointer，实际上就是IMemory::pointer()。具体源码如下：

```
/*frameworks/native/libs/binder/IMemory.cpp*/
void* IMemory::pointer() const {
    ssize_t offset;
    sp<IMemoryHeap> heap = getMemory(&offset);
    void* const base = heap!=0 ? heap->base() : MAP_FAILED;
    if (base == MAP_FAILED)
        return 0;
    return static_cast<char*>(base) + offset;
}
```

这个函数首先调用BpMemory::getMemory得到IMemoryHeap，也就是BpMemoryHeap，然后调用其base()方法（base实际上就直接调用了getBase）：

```
void* BpMemoryHeap::getBase() const {
    assertMapped();
    return mBase;
}
```

很精练的两句话，看来玄机应该就在下面这个函数中了：

```
void BpMemoryHeap::assertMapped() const
{
    if (mHeapId == -1) {//当前是第一次调用，说明还没有做过映射
        sp<IBinder> binder(const_cast<BpMemoryHeap*>(this)->asBin
        sp<BpMemoryHeap> heap(static_cast<BpMemoryHeap*>(find_hea
        heap->assertReallyMapped();
       …
    }
}
```

假如mHeapId == —1，说明还没有把共享内存映射到虚拟空间中来。考虑到一个进程可能会有多个BpMemoryHeap对应同一块共享内存，因而它使用find_heap来判断是否已经存在一个与binder相对应的heap。如果是直接增加计数返回即可，否则还需要做映射。具体实现如下：

```
void BpMemoryHeap::assertReallyMapped() const
{
    if (mHeapId == -1) {
        Parcel data, reply;
        data.writeInterfaceToken(IMemoryHeap::getInterfaceDescrip
        status_t err = remote()->transact(HEAP_ID, data, &reply);
        int parcel_fd = reply.readFileDescriptor();//获取AudioFlir
                                                   //设备文件描述符
        …
        int fd = dup( parcel_fd );
       …
        Mutex::Autolock _l(mLock);
        if (mHeapId == -1) {
            mRealHeap = true;
            mBase = mmap(0, size, access, MAP_SHARED, fd, offset)
          …
}
```

如果大家暂时还看不懂writeInterfaceToken、Parcel、remote()->transact等变量和函数方法是什么意思，建议先放一放，等学习了Binder章节后再回过头来分析。简单地说，remote()->transact就是向Server端发起了一个请求（HEAP_ID），即得到文件描述符。如下BnMemoryHeap源码所示：

```
status_t BnMemoryHeap::onTransact(uint32_t code, const Parcel& da
{
    switch(code) {
       case HEAP_ID: {
            CHECK_INTERFACE(IMemoryHeap, data, reply);
            reply->writeFileDescriptor(getHeapID());
          …
}
```

函数getHeapID的实现如下：

```
/*frameworks/native/libs/binder/MemoryHeapBase.cpp*/
int MemoryHeapBase::getHeapID() const {
    return mFD;
}
```

所以，reply.readFileDescriptor得到的就是在AudioTrack中可用的ashmem文件描述符。接着就可以通过这个fd进行mmap了，从而成功地将AudioFlinger中创建的共享内存映射到AudioTrack所在的进程空间中。

Android系统中的匿名共享机制涉及了设备驱动、Binder原理等一系列技术，所以初学者可能很难理解。建议大家在充分学习相关基础知识后，再集中精力攻克这一难关。

4.9 JNI

在后续章节的原理分析中，我们经常要涉及JNI（Java Native Interface）这一概念。它是一种允许运行于JVM的Java程序去调用（反向亦然）本地代码（通常JNI面向的本地代码是用C、C++以及汇编语言编写的）的编程框架。本地代码通常与硬件或者操作系统有关联，因而会在一定程度上破坏Java本身的可移植性。不过有时这种方法是必需的，如Android系统中就采用了大量JNI手段去调用本地层的实现库。

通常有以下3种情况需要用到JNI。

- 应用程序需要一些平台相关的feature的支持，而Java无法满足。
- 兼容以前的用其他语言书写的代码库。使用JNI技术可以让Java层的代码访问到这些旧库，实现一定程度的代码复用。
- 应用程序的某些关键操作对运行速度要求较高。这部分代码可以用底层语言如汇编来编写，再通过JNI向Java层提供访问接口。

JNI在Android系统中扮演了非常重要的角色，我们有必要先对它进行讲解。其主要涉及以下两方面。

- Java Code->Native Code

Java语言如何调用本地层的函数方法与变量。

- Native Code->Java Code

虽然多数情况下都是APK应用程序通过Java源码去调用本地层代码，但在有些情况下本地层代码也同样需要访问Java层的实现——包括用Java实现的函数与变量。

4.9.1 Java函数的本地实现

创建一个可供Java代码调用的本地函数的步骤如下：

- 将需要本地实现的Java方法加上native声明；
- 使用javac命令编译Java类；

- 使用javah生成.h头文件；
- 在本地代码中实现native方法；
- 编译上述的本地方法，生成动态链接库；
- 在Java类中加载这一动态链接库；
- Java代码中的其他地方可以正常调用这一native方法。

下面我们以一个范例来说明这一过程：

```
/*TestJNI.java*/
class TestJNI
{
     private native void testJniAdd(int v1, int v2);  //用native关
     public void test()
     {
          System.out.println ("The result:" + testJniAdd(2,3));
     }
     public static void main(String args[])
     {
          TestJNI JniExample = new TestJNI();
          JniExample.test();
     }
     static
     {
          System.loadLibrary("testJniLib");/*加载本地代码实现库*/
     }
}
```

接下来，首先使用javac编译上面的TestJNI.java，生成TestJNI.class。然后利用javah生成TestJNI.h文件，其中就包含了JNI方法的声明体：

```
JNIEXPORT void JNICALL Java_TestJNI_testJniAdd (JNIEnv *, jobject
```

有了TestJNI.h后，我们将上述的函数声明用本地语言来实现。功能很简单——直接将两个数值相加的和返回给调用者：

```
JNIEXPORT void JNICALL Java_TestJNI_testJniAdd(JNIEnv * env, jobj
{
     return value1 + value2;
}
```

最后，只要将上述包含JNI方法的文件（比如.c、.cpp等。这里有

一个小技巧来快速创建它们，就是将上面javah生成的.h改个后缀名，这样所有的声明体和头文件引用都不用再手工输入了）编译成动态链接库，然后让TestJNI加载进去，整个JNI框架就运行起来了。

关于如何编译生成动态链接库，已经有非常多的参考资料——比如利用VS Studio，或者采用某些开源的小工具等。其实，Android系统本身也提供了非常方便的实现来完成这一功能——NDK（Native Development Kit）。

这里简要介绍下如何通过NDK生成JNI库。首先当然是要下载NDK包，可以从官网获取到：

http://developer.android.com/tools/sdk/ndk/index.html

然后，依次执行以下步骤来编译动态库。

- 将之前生成的Jni本地源码文件放在工程某个目录下，建议是<project>/jni/
- 在<project>/jni中生成一个Android.mk文件来描述本地源码。下面是一个范例：

```
/*Android.mk*/
LOCAL_PATH := $(call my-dir)
include $(CLEAR_VARS)

LOCAL_MODULE    := testJniLib
LOCAL_SRC_FILES := testJniLib.c

include $(BUILD_SHARED_LIBRARY)
```

注意

我们要编译的是“BUILD_SHARED_LIBRARY”。

- 在<project>/jni中生成一个Application.mk（可选）。
- 利用如下命令执行编译：

```
cd <project>
```

```
<ndk>/ndk-build
```

从上面的Java_TestJNI_testJniAdd方法中，我们看到诸如JNIEnv、jobject这样的参数类型，而Java层的testJniAdd本身并没有带这两个参数。第一反应是它们应该为类似于C++中的this指针，即代表了类的一个实例化对象。事实上也确实如此，JNIEnv的定义如下：

```
typedef const struct JNINativeInterface *JNIEnv;
```

JNINativeInterface是一个JNI的本地接口，包含了很多实用函数（稍后我们再做详细分析）而jobject则代表了这个本地类方法对应的Java类实例。

Java_TestJNI_testJniAdd函数中的最后两个参数，才是函数的真正入参。不过和我们之前看到的数据类型不同，它们是jint，而不是int。这是因为JNI已经对所有的标准数据类型做了相应的typedef，可以参照表4-6和表4-7。

表4-6　JNI基础类型对照表

Java类型	本地类型	说　　明
boolean	jboolean	unsigned 8 bits
byte	jbyte	signed 8 bits
char	jchar	unsigned 16 bits
short	jshort	signed 16 bits
int	jint	signed 32 bits

long	jlong	signed 64 bits
float	jfloat	32 bits
double	jdouble	64 bits
void	void	void

表4-7　　ＪNI引用数据类型对照表

Java类型	本地类型	**Java**类型	本地类型
All objects	jobject	char []	jcharArray
java.lang.Class instances	jclass	short []	jshortArray
java.lang.String instances	jstring	int []	jintArray
arrays	jarray	long []	jlongArray
object []	jobjectArray	float []	jfloatArray
boolean []	jbooleanArray	double []	jdoubleArray

byte []	jbyteArray	java.lang.Throwable objects	jthrowable

基础类型的变量可以在Java和本地代码间进行复制，而Java对象需要通过引用类型进行传递。JVM需要跟踪所有它传递给本地代码的对象实例，这样才能保证它们不被垃圾回收器收回。而当本地代码不再使用这些对象时，也要及时通知JVM。

这里再顺便介绍一下Type Signature，它是数据类型的标签，如表4-8所示。

表4-8　Type Signature

Java Type	Type Signature	Java Type	Type Signature
boolean	Z	float	F
byte	B	double	D
char	C	fully-qualified-class	L fully-qualified-class
short	S	type[]	[type
int	I	method type	(arg-types) ret-type
long	J		

比如一个Java方法：

```
long aMethod(int n, String s, int[] arr);
```

那么就可以表示为:

```
(ILjava/lang/String;[I]J
```

其中，括号里表示的是函数方法的参数，尾部是返回值。这样的表达方式看起来非常简洁，而且可以用字符串的形式来表达，因此在JNI中使用非常广泛。

4.9.2　本地代码访问JVM

上一小节我们讲解了如何为一个Java函数创建本地实现，但这并不是JNI的全部。试想一下，既然Java可以调用C/C++等语言编写的源码，那么反过来是否也可行呢？答案是肯定的。本地层同样可以访问JVM空间，这是JNI的另一个重要组成部分。本小节中我们将向大家展示如何做到这种“逆向”的操作。

先来看看前面提到的JNIEnv类型的变量，它是本地代码函数中的第一个参数，代表了一个JNI interface pointer。其本质是指向了一个函数列表的指针，如图4-21所示。

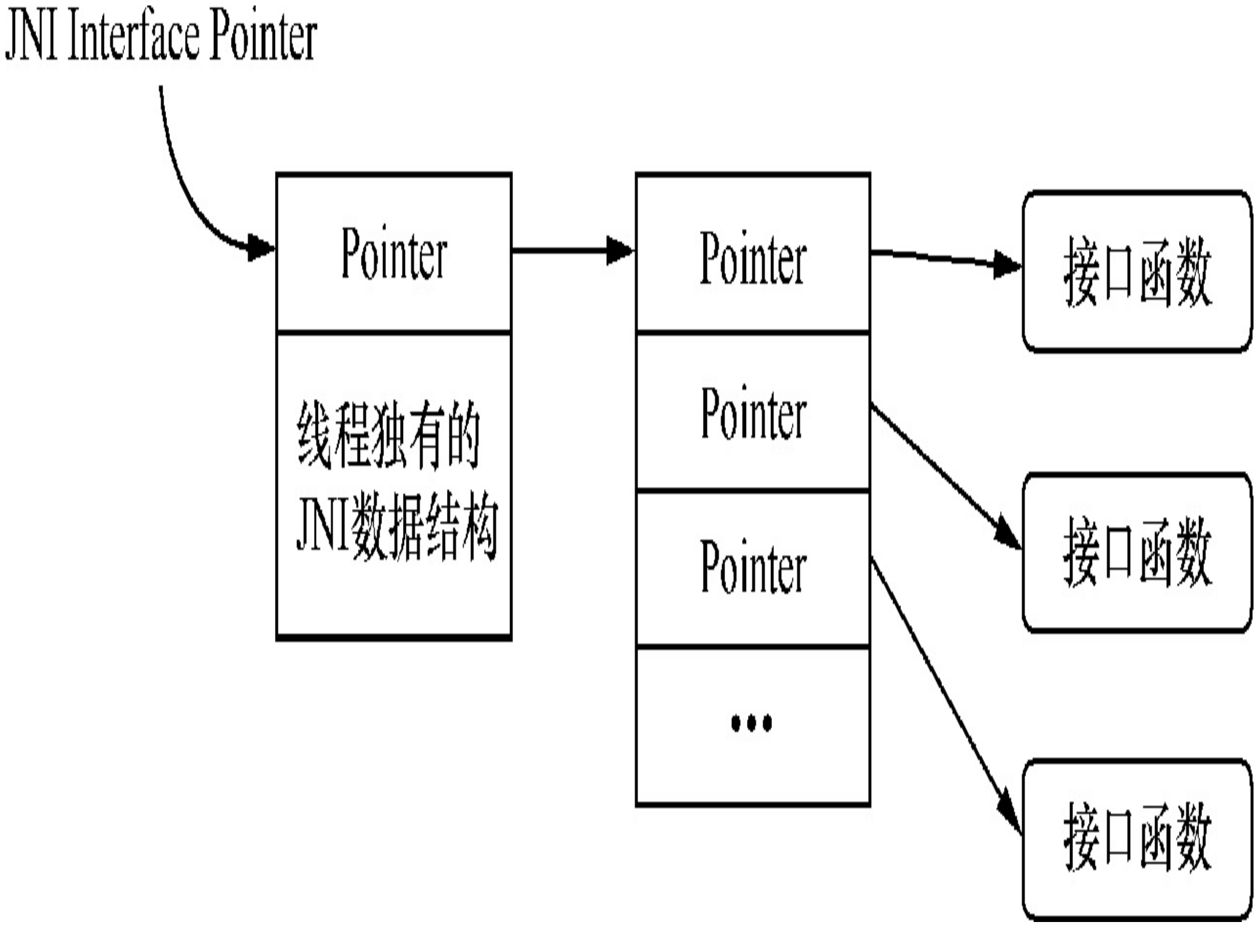

▲图4-21 JNI Interface Pointer

JNI Interface Pointer之所以没有直接做成“硬编码”形式的函数调用，而采用如图4-21所示的函数指针形式，是为了给JNI的实现带来更多灵活性。它有点类似于C++中虚函数的概念，在运行时才会动态决定需要真正被调用的目标函数。

JNI通过名称和Type Signatures来访问Java类中的域（fields）和方法（methods）。比如下面两行语句：

```
jmethodID mid = env->GetMethodID(cls, "methodExample", "(ILjava/l
          /*首先通过名称“methodExample”和它的type signature来找到这个方
jdouble result = env->CallDoubleMethod(obj, mid, 10, str);
          /*通过相应的CallXXXMethod()来访问到此ID值所指向的方法*/
```

除了域和方法，JNI其实还提供了一系列的函数来完成对Java的各种访问和控制，如异常处理、本地和全局引用、字符串操作、数组操作和反射支持等。这些函数都包含在了JNIEnv这个变量中，因而每个本地

函数都能使用它的第一个参数来获取JNI为它们提供的丰富的功能接口。

由于这个函数指针列表中包含的接口数量众多，接下来我们只挑选其中常用的一部分操作来做简单的介绍。有需要的读者可以参阅官方文档来做进一步了解：（http://docs.oracle.com/javase/6/docs/technotes/guides/jni/spec/functions.html）。

```
Version Information
jint GetVersion(JNIEnv *env);
```

返回本地方法接口的版本号，即：

```
JDK/JRE 1.1, GetVersion() --> 0x00010001.
JDK/JRE 1.2, GetVersion() --> 0x00010002.
JDK/JRE 1.4, GetVersion() --> 0x00010004.
JDK/JRE 1.6, GetVersion() --> 0x00010006.
```

Class Operations

```
jclass FindClass(JNIEnv *env, const char *name);
```

参数说明：

```
env: JNI Interface Pointer
name: fully-qualified class name, 即用“/”隔开的完整的package name
```

从Java2 SDK release 1.2开始，FindClass自动定位与此本地方法相关联的class loader。如果此本地方法属于system class，则不会有相对应的class loader。此时便会使用：ClassLoader.getSystem ClassLoader；否则将由相应的loader来完成name所指定的class的加载。

Accessing Fields of Objects

（1）jfieldID GetFieldID（JNIEnv *env，jclass clazz,const char *name，const char *sig）;

参数说明：

```
env: JNI Interface Pointer
```

clazz: Java class object
name: 以0为结束符的UTF-8编码字符串，表示域名
sig: 以0为结束符的UTF-8编码字条串，表示域名的标签

返回值：成功则返回field ID，否则就是null。

此函数返回一个类实例（非静态）中的域的ID，这个域由参数中的name和signature指定。只有先得到了某个域的ID值，才能使用Get和set方法来继续对它进行操作。

（2）NativeType Get<type>Field(JNIEnv *env, jobject obj,jfieldID fieldID);

通过上面接口获取到field ID后，我们可以进一步取得此field的值。

参数值的含义和GetFieldID是一样的，此处不再赘述。要注意的是<type>代表了不同数据类型的field，如Object、Boolean、Byte等：

```
GetObjectField()    //Field的类型为object
GetBooleanField()   //Field的类型为boolean
GetByteField()      //Field的类型为byte
GetCharField()      //Field的类型为char
GetShortField()     //Field的类型为short
```

（3）void Set<type>Field(JNIEnv *env, jobject obj, jfieldID fieldID,NativeType value);

设置field的值，它和Get<type>Field的参数差别在于最后的NativeType，即需要给这个域设定新的值。和Get一样，type指代了不同数据类型的field。

Calling Instance Methods

（1）jmethodID GetMethodID (JNIEnv *env, jclass clazz,const char *name, const char *sig);

返回一个类或接口对象中的方法（非静态）的ID值。

参数说明：

```
env: JNI Interface Pointer
clazz: Java class object
name: 以0为结束符的UTF-8编码字符串，代表方法名称
sig: 以0为结束符的UTF-8编码字符串，代表方法的method signature
```

（2）NativeType Call<type>Method(JNIEnv *env, jobject obj,jmethodID methodID, ...);

```
NativeType Call<type>MethodA(JNIEnv *env, jobject obj,jmethodID m
NativeType Call<type>MethodV(JNIEnv *env, jobject obj,jmethodID m
```

通过GetMethodID获得方法的ID后，就可以利用这个值来调用相应的Java方法了。上面列出的3个函数的区别在于它们传递参数的机制不同。

- Call<type>Method

从函数的声明可以看出，这种方式的调用会将参数全部直接放在method ID后面。

- Call<type>MethodA

以数组的形式传递参数，即先将所有参数放入args变量中。

- Call<type>MethodV

以va_list的形式传递参数。

<type>类型和之前提到的几个函数都是一样的，下面举几个例子：

```
CallVoidMethod()
CallVoidMethodA()
CallVoidMethodV()
CallObjectMethod()
CallObjectMethodA()
CallObjectMethodV()
CallBooleanMethod()
CallBooleanMethodA()
CallBooleanMethodV()
```

我们在描述方法和域的访问函数时，都特别强调了是针对非静态的情况。对于静态的方法与域，JNI还有专门的访问方式。不过原理都是

大同小异的，请读者参考相关文档。而JNI提供的诸如字符串、数组等操作都比较简单，这里不再详细讨论。

在后续章节的分析中，我们还会针对具体场景对JNI做进一步讲解。

4.10　Java中的反射机制

Java中创建一个Class类最常见的方式如下：

```
FileOutputStream fout = <strong>new</strong> FileOutputStream(fd)
```

这种情况意味着我们在编译期便可以确定Class类型。此时编译器可以对new关键字做很多优化工作，所以这种场景下的运行效率通常是最好的，是开发人员的首选方式。

而对于那些无法在编译阶段就得到确定的Class类的情况，我们希望有一种技术可以在程序运行过程中去动态地创建一个对象——这就是反射机制。反射机制能够赋予程序检查和修正运行时行为的能力，下面我们就以Class类的动态创建为例，简单分析一下其内部的实现原理：

```
Class<?> clazz = null;
        try {
            clazz = Class.forName("android.media.MediaMetadataRet
            instance = clazz.newInstance();
            Method method = clazz.getMethod("setDataSource", Stri
            method.invoke(instance, filePath);
```

Class.forName通过native函数classForName调用到本地层，在Android N版本中对应的具体函数如下：

```
/*art/runtime/native/java_lang_Class.cc*/
static jclass Class_classForName(JNIEnv* env, jclass, jstring jav
jboolean initialize, jobject javaLoader) {
  ScopedFastNativeObjectAccess soa(env);
  ScopedUtfChars name(env, javaName);
  …
  Handle<mirror::ClassLoader> class_loader(hs.NewHandle(soa.Decod
  ClassLinker* class_linker = Runtime::Current()->GetClassLinker(
  Handle<mirror::Class> c(
      hs.NewHandle(class_linker->FindClass(soa.Self(), descriptor
class_loader)));
  …
  return soa.AddLocalReference<jclass>(c.Get());
}
```

可见，forName最终是通过ClassLinker::FindClass来找到目标类对象的。反射机制提供的其他接口也是类似的——只有经过虚拟机的统

一管理，才有可能既为程序提供灵活多样的动态能力，同时又保证了程序的正常运行。

对于ClassLinker的进一步分析，读者可以参考本书的虚拟机章节。

4.11　学习Android系统的两条线索

本章详细讲解了操作系统的一系列基础知识，包括计算机体系的结构、操作系统的概念以及操作系统的一大核心，即进程间通信和内存管理机制。另外，我们还穿插讲解了这些知识点在Android系统中的应用与扩展（其中Android的进程/线程管理和进程间通信因为内容较多，将在后面两个章节进行专门讲解）——目的就是为读者分析Android的各子系统原理打下坚实的理论基础。

本书接下来的内容编排有两条线索。

- 主线：操作系统的体系结构、硬件组成。
- 辅线：在主线的基础上，以Android系统的5层框架为辅，逐一解析各层框架中的重要元素，或拾级而上，或深入浅出，直至问题的最根源处。

通过以上解释，读者应该可以想象得到本书的内容编排其实是立体的，即平面（各子系统）+高度（每个元素在5层结构上都有所体现）的形式——更为重要的一点，这同时也是Android系统的设计线索。

我们以“进程管理”为例，如图4-22所示。

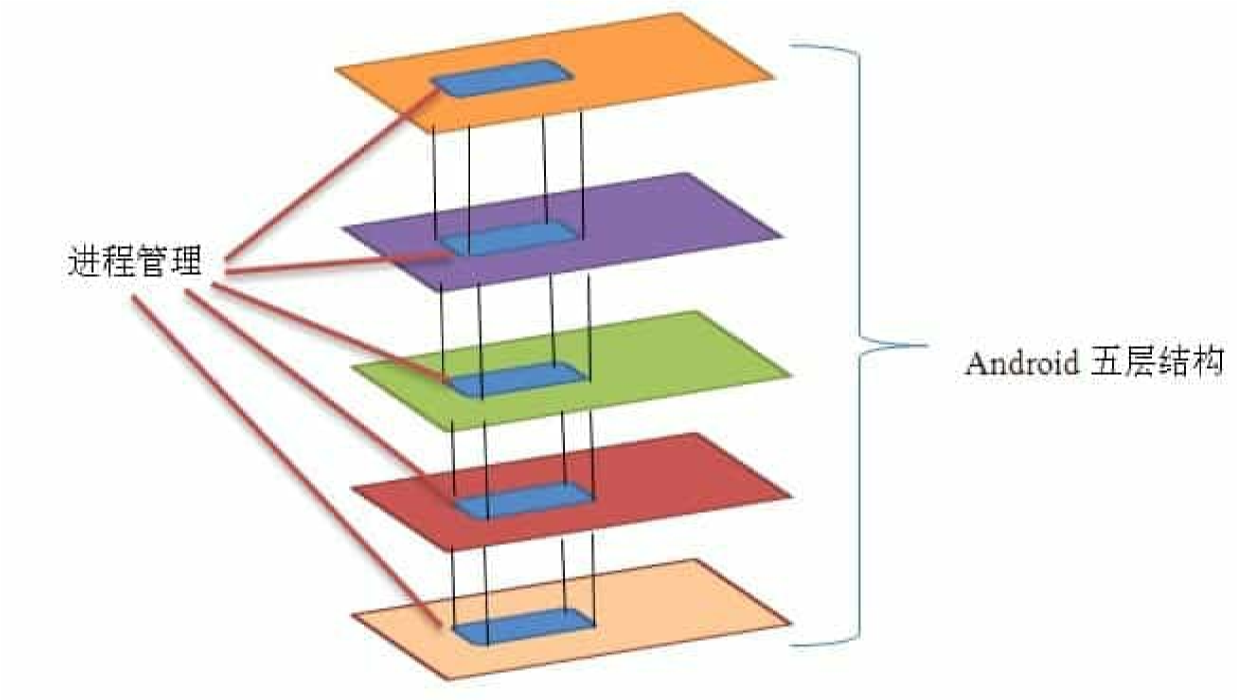

▲图4-22　本书内容的编排架构

希望读者无论是阅读本书，还是研究Android系统，都能牢牢把握住这两条线索——相信一定会有不少收获。

第5章

Android进程/线程和程序内存优化

5.1 Android进程和线程

进程（Process）是程序的一个运行实例，以区别于“程序”这一静态的概念；而线程（Thread）则是CPU调度的基本单位。当前大部分的操作系统都支持多任务运行，这一特性让用户感到计算机好像可以同时处理很多事情。显然在只有一个CPU核心的情况下，这种“同时”是一种假象。它是操作系统采用分时的方法，为正在运行的多个任务分配合理的、单独的CPU时间片来实现的。举一个例子，假设当前系统中有5个任务，如果采用“平均分配”法且时间片为10ms的话，那么各个任务每隔40ms就能被执行一次。只要机器速度够快，用户的感觉就是所有任务都在同步运行。

那么，Android中的程序和进程具体是什么概念呢？

我们知道，一个应用程序的主入口一般都是main函数，这基本上成了程序开发的一种规范——它是“一切事物的起源”。而main()函数的工作也是千篇一律的。总结如下：

- 初始化

  比如Windows环境下通常要创建窗口、向系统申请资源等。

- 进入死循环

  并在循环中处理各种事件，直到进程退出。

这种模型是“以事件为驱动”的软件系统的必然结果，因此几乎存在于任何操作系统和编程语言中。

当然，这种“一切从零开始”的开发模式显然太过费时费力。为了简化开发人员的工作，很多IDE（Integrated Development Environment）工具将程序编制中烦琐而又一成不变的部分抽取出来，以向导模板的方式自动完成。这样工程人员就可以把精力放在更多有意义的事情上。比如MFC编程，它提供给软件人员的入口就摆脱了传统的主函数，而是强调“图形控件”为中心的开发模式——只要通过简单的操作就可以得到带各种UI界面的程序框架。Android的做法与此相似。比如可以通过Eclipse环境搭配Android专用的ADT工具，来快速生成各种应用程序的原型；也可以利用layout来布局自己的UI界面。

IDE也带来了一些弊端。对于Android应用开发者而言，通常面对的都是Activity、Service等组件，并不需要特别关心进程是什么。因而产生了一些误区，如部分研发者认为系统四大组件就是进程的载体。

这些组件确实很符合我们对进程的印象。不过很可惜，它们不能算是完整的进程实例，最多只能算是进程的组成部分。从AndroidManifest.xml中也可以得到一点提示——这个xml文件是对应用程序的声明和描述，如范例所示：

```
<manifest xmlns:android="http://schemas.android.com/apk/res/andro
android.launchperf">
<application android:label="Launch Performance">
 <activity android:name="SimpleActivity" android:label="Simple Ac
  <intent-filter>
   <action android:name="android.intent.action.MAIN" />
   <category android:name="android.intent.category.DEFAULT" />
  </intent-filter>
 </activity>
…
```

可以看到，Activity的外围有一个名为<application>的标签。换句话说，四大组件只是“application”的“零件”。本小节接下来的内容中将通过几个实验来让读者有个更全面的认识，这将对大家后续理解ActivityManagerService，Binder进程间通信产生积极的意义。

实验内容如表5-1所示。

表5-1　　进程和线程实验列表

序号	参　与　类	实 验 内 容
1	ActivityThreadTest	通过Debug一个普通的Activity工程，来观察它运行时的进程情况
2	ServiceThreadTest	通过Debug一个普通的Service工程，来观察它运行时的进程情况，并与第一个例子进行比较
3	ActivityThreadTest, ActivityThreadTest2	在实验1的package包中新增一个Activity，并且前一个Activity将通过startActivity()启动后者。观察进程的变化情况
4	ActivityThreadTest, ActivityThreadTest2	在实验3的基础上，论证同一个包中的两个组件是否运行于相同的进程空间中

实验1

首先我们在Eclipse中通过ADT向导新建一个普通的Activity工程，命名为“ActivityThreadTest”，如图5-1所示。

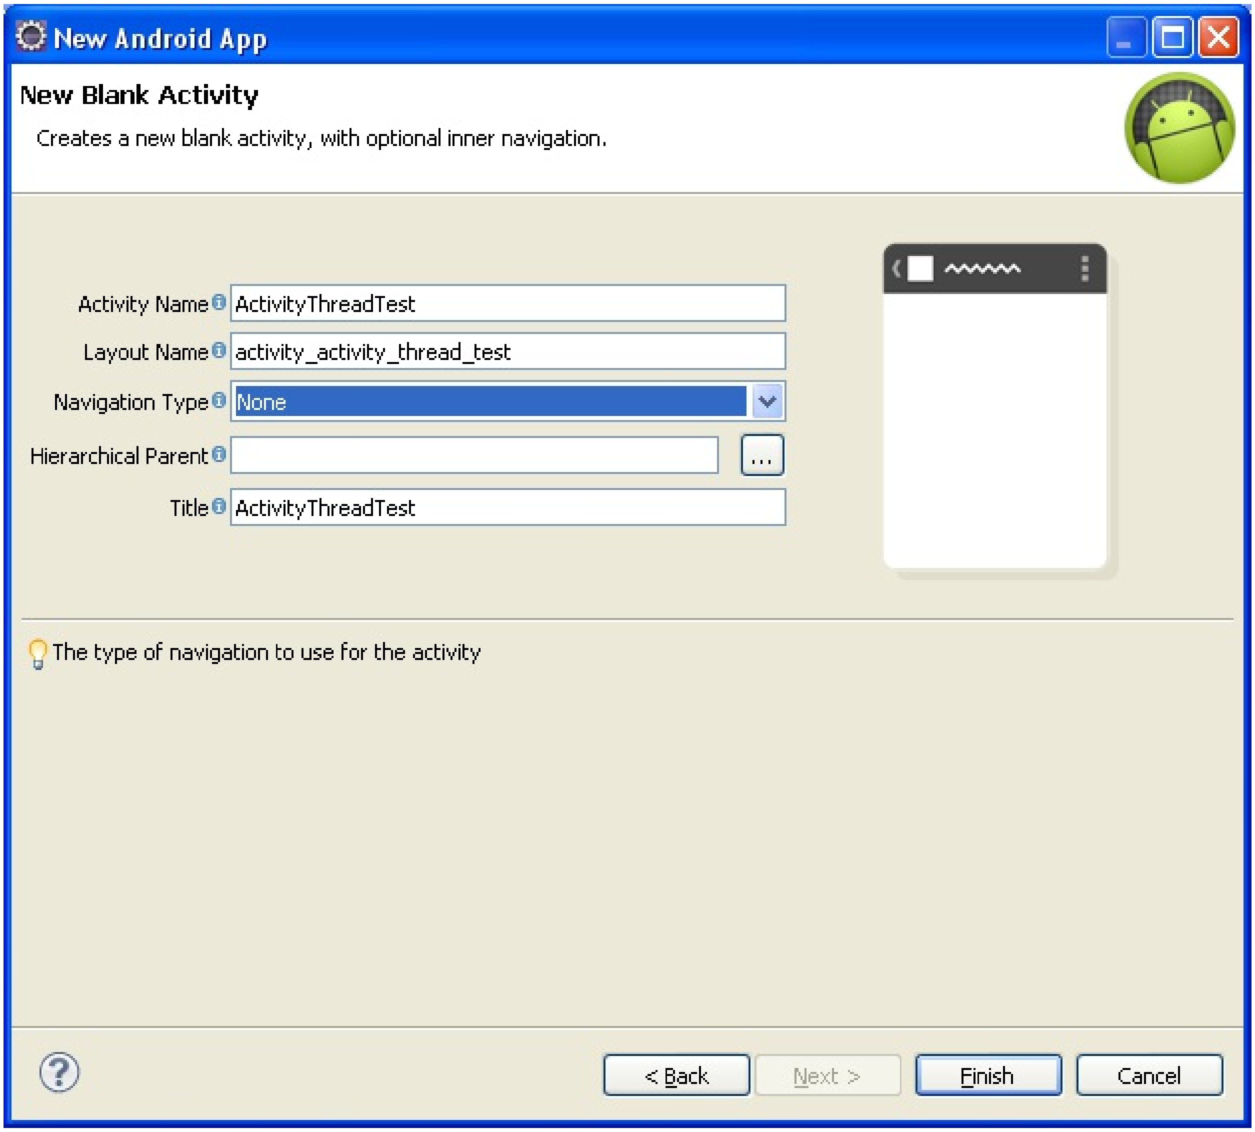

▲图5-1　新创建一个普通的Activity工程

然后在自动生成的源码中的onCreate()函数入口处打上断点，如下所示。

```
@Override
public void onCreate(Bundle savedInstanceState) {
    super.onCreate(savedInstanceState);
```

那么当这个Activity启动后，将会生成几个Thread呢（是不是只会有一个主线程）？如图5-2所示。

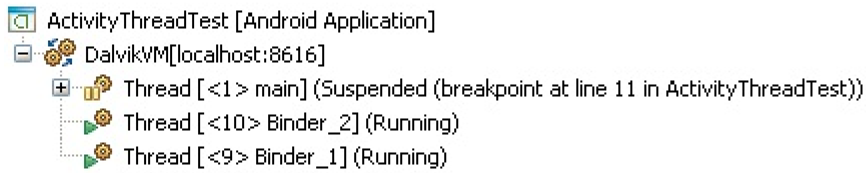

▲图5-2　一个Activity程序所包含的线程数

一个由向导诞生的、没有任何实际功能的Activity程序，居然启动了这么多线程。其中除了有我们最熟悉的main thread（即图5-2中的Thread[<1> main]）外，还有两个Binder Thread。

我们还需要从这个实验中解决一个重要问题，即主线程到底是怎么产生的。很简单，看下函数堆栈就知道了，如图5-3所示。

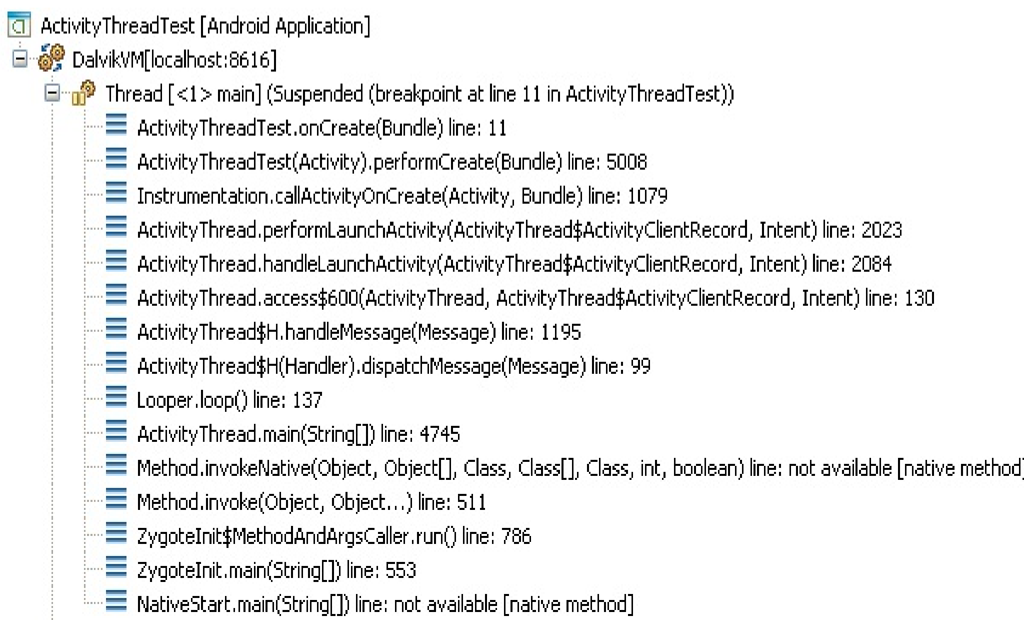

▲图5-3　主线程的函数堆栈

可以清楚地看到，主线程由ZygoteInit启动，经由一系列调用后最终才执行Activity本身的onCreate()函数。最重要的是，我们从中了解到Zygote为Activity创建的主线程是ActivityThread：

```
/*frameworks/base/core/java/android/app/ActivityThread.java*/
public static void main(String[] args) {
        SamplingProfilerIntegration.start();
        CloseGuard.setEnabled(false);
```

```
        Process.setArgV0("<pre-initialized>");
        Looper.prepareMainLooper(); /*只有主线程才能调用这个函数，普通纟
                                          请参见本章后续小节对Looper
        if (sMainThreadHandler == null) {
            sMainThreadHandler = new Handler(); /*主线程对应的Handl
        }

        ActivityThread thread = new ActivityThread(); /*这个main()
                                                                因此在这
        thread.attach(false); /*Activity是有界面显示的，这个函数将与Wi
                                 建立联系。详见本书中的显示系统章节*/
       …
        Looper.loop(); /*主循环开始*/
        throw new RuntimeException("Main thread loop unexpectedly
                                                    行到这里，说明退出了上面的
    }
```

那么，用于Binder的那些线程又是什么时候创建的呢？这个问题留到后面Binder章节再做详细解答。

实验2

Zygote为实验1中的应用程序分配的主线程是ActivityThread。这是不是说所有Android应用程序的主线程，都是ActivityThread？所以这个实验中，我们将使用另外一个组件——Service来构建应用程序（其他组件也是类似的，大家可以试验）。另外，读者还可以思考一下，如果是Service组件，它启动时是否也会有这么多线程。换句话说，上面看到的Binder线程是不是Activity应用进程独有的。

我们启动一个Service程序来揭开其中的真相。服务本身并没有什么实质功能，而且为了突出重点很多细节部分都省略了，希望读者注意这点：

```
/*ServiceThreadTest 的AndroidManifest.xml*/
…
<application android:label="@string/app_name"
        android:icon="@drawable/ic_launcher"
        android:theme="@style/AppTheme">
 <service android:name=".ServiceThreadTest">
  <intent-filter/>
 </service>
</application>
…
```

下面是ServiceThreadTest的一些主要函数实现：

```
/*ServiceThreadTest.java*/
public class ServiceThreadTest extends Service
{
      public void onCreate()
      {
            Log.i("ServiceThreadTest", "Service created");/*将断点设
      }

      @Override
      public void onDestroy()
      {
            super.onDestroy();
            Log.i("ServiceThreadTest", "Service destroyed");
      }
      @Override
      public void onStart(Intent intent, int startId)
      {
            super.onStart(intent, startId);
            Log.i("ServiceThreadTest", "Service started");
      }
}
```

这样一个简单的Service程序就构建完成了。接下来通过startService()来启动这个服务，并将断点设在onCreate()中，如图5-4所示。

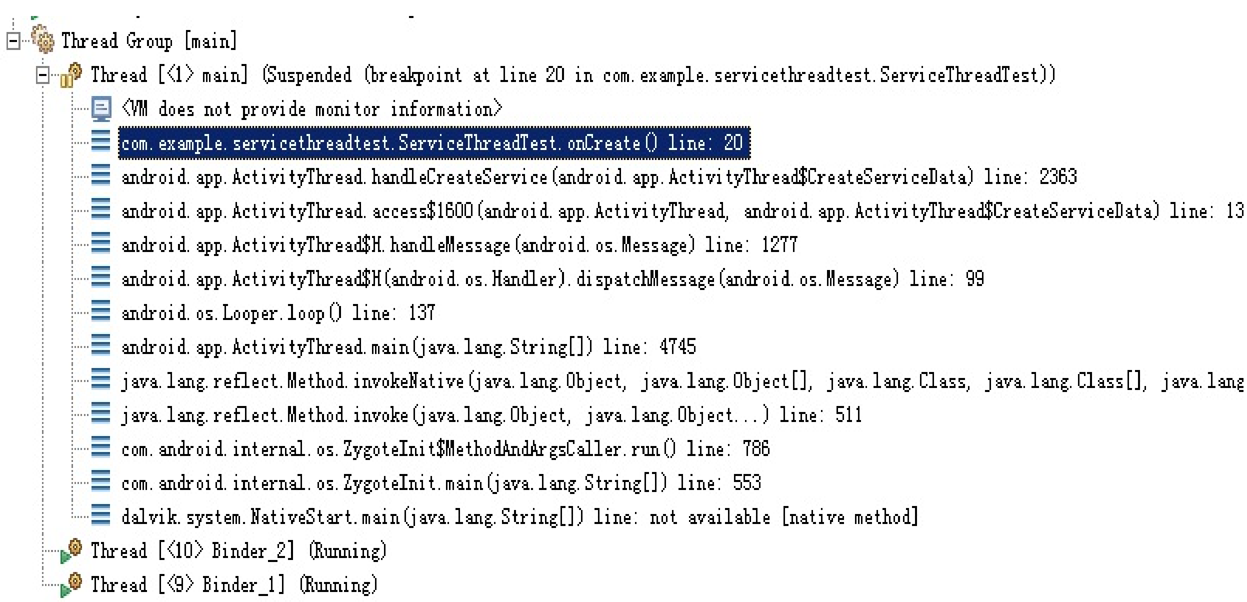

▲图5-4　一个简单的Service程序

根据图5-4描述的内容，可以得到以下两个结论。

- Service也是寄存于ActivityThread之中的，并且启动流程和Activity基本一致。
- 启动Service时，也同样需要两个Binder线程的支持。

先记住这两点，后期我们在源码分析中会找到根源所在。

实验3

上面已经证明了Activity和Service应用程序的主线程都是ActivityThread。那么如果同一个程序包中有两个Activity（或Service），它们是什么关系？需要有多少线程的支持？

这个实验的代码同样很简单，只是在第一个例子的基础上又增加了一个Activity，命名为ActivityThreadTest2：

```
/*AndroidManifest.xml*/
<activity android:name=".ActivityThreadTest" /*第一个Activity*/
          android:label="@string/title_activity_activity_thread_t
 <intent-filter>
  <action android:name="android.intent.action.MAIN" />
  <category android:name="android.intent.category.LAUNCHER" />
 </intent-filter>
</activity>
<activity android:name=".ActivityThreadTest2" /*新增的Activity*/
          android:label="@string/title_activity_activity_thread_t
</activity>
```

在具体源码的实现上，我们在ActivityThreadTest中通过startActivity来启动第二个Activity，即ActivityThreadTest2。这里有一个知识点要清楚：当后者运行起来后，前一个ActivityThreadTest并没有完全退出，而是被压入Activity栈中。所以当ActivityThreadTest2退出时，它可以被重新显示出来：

```
/*ActivityThreadTest.java*/
public void onCreate(Bundle savedInstanceState)
{
     super.onCreate(savedInstanceState);
     Log.i("ActivityThreadTest1", "We are in ThreadTest1");
```

```
        setContentView(R.layout.activity_activity_thread_test);
        Intent intentThread2 = new Intent(this, ActivityThreadT
        startActivity(intentThread2);/*启动第二个Activity*/
    }
```

看看当断点停在ActivityThreadTest2的onCreate()函数中时，线程的分布情况，如下所示。

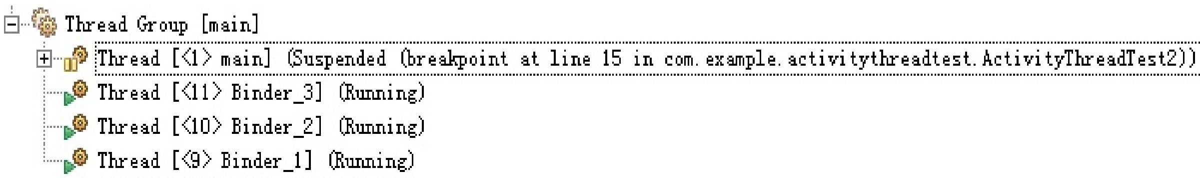

其中揭示了以下几个现象。

- 当ActivityThreadTest2被执行时，主线程始终只有一个。
- 此时ActivityThreadTest暂时退出了运行。
- Binder线程数量有所变化，读者在学习了Binder章节后就应该知道是什么原因了。

带着这些感观印象，我们进入下一个实验。

实验4

按照Android系统的设计：

“By default, all components of the same application run in the same process and thread (called the "main" thread)”。

上面这句话还可以理解为：对于同一个AndroidManifest.xml中定义的四大组件，除非有特别声明（参见后面的讲解），否则它们都运行于同一个进程中（并且均由主线程来处理事件）。

那么，如何证明呢？

根据操作系统的基础知识，如果两个对象处于同一个进程空间中，那么内存区域应该是可共享访问的。所以在本实验中，我们将利用这个原理来论证实验3中先后启动的同一个包里的两个Activity是否共存于

同一个进程中。

先让ActivityThreadTest拥有一个static的变量，如下所示。

```
/*ActivityThreadTest.java*/
public class ActivityThreadTest extends Activity
{
     static int <strong>TestForCoexist</strong> = -1; //这个变量一
     @Override
     public void onCreate(Bundle savedInstanceState)
     {
          super.onCreate(savedInstanceState);
          Log.i("ActivityThreadTest1", "We are in ThreadTest1");
          setContentView(R.layout.activity_activity_thread_test);
          Intent intentThread2 = new Intent(this, ActivityThreadT
          <strong>TestForCoexist</strong> = 2; /*在启动第二个Activi
                                      程中的话，ActivityThreadTest是没有办
          startActivity(intentThread2);
     }
     …
}
```

ActivityThreadTest中有一个静态的变量TestForCoexist。其初始值为1，并在Activity启动后（onCreate中）被修改为2。

接着看看ActivityThreadTest2的源码实现：

```
/*ActivityThreadTest2.java*/
public class ActivityThreadTest2 extends Activity
{
     @Override
     public void onCreate(Bundle savedInstanceState)
     {
          super.onCreate(savedInstanceState);
          Log.i("ActivityThreadTest2", "We are in ThreadTest2");
          setContentView(R.layout.activity_activity_thread_test);
          Log.i("ActivityThreadTest2", "TestForCoexist="
                    + ActivityThreadTest.TestForCoexit); //实验结果
     }
     …
}
```

我们运行这个应用程序，来看看最终的输出，如下所示。

PID	TID	Application	Tag	Text
2236	2236	com.example.activitythreadtest	Trace	error opening trace file: No such fil
2236	2236	com.example.activitythreadtest	ActivityThreadTest1	We are in ThreadTest1
2236	2236	com.example.activitythreadtest	ActivityThreadTest2	We are in ThreadTest2
2236	2236	com.example.activitythreadtest	ActivityThreadTest2	TestForCoexit=2

这就足够证明两个Activity是在同一个进程空间中了。理由如下：

- 第二个Activity得到的值是2。假设二者不是在相同的进程中，ActivityThreadTest2只是单纯地import了ActivityThreadTest，那么它得到的值应该是初始值1；而ActivityThreadTest对自己进程中变量的修改，对于其他进程是不可见的。

- 仔细观察，还会发现二者所处的应用程序PID和TID值是相同的。这都证明了一个结论，那就是同一个程序包里的两个Activity默认确实都运行于同一个进程中。

当然，Android还提供了特殊的方式让不是同一个包里的组件也可以运行于相同的进程中。优势就是，它们可以非常方便地进行资源共享，而不用经过费时费力的进程间通信。分为两种情况：

1．针对个别组件

可以在AndroidManifest.xml文件中的<activity>、<service>、<receiver>和<provider>（四大组件都支持，可以根据需要来添加）标签中加入android:process属性来表明这一组件想要运行在哪个进程空间中。

2．针对整个程序包

可以直接在<application>标签中加入android:process属性来指明想要依存的进程环境。

结论

经过本节的4个实验，相信大家对Android中的进程和线程已经有了新的认识。下面再来做个小结。

- 四大组件并不是程序（进程）的全部，而只是它的“零件”。
- 应用程序启动后，将创建ActivityThread主线程。
- 同一个包中的组件将运行在相同的进程空间中。
- 不同包中的组件可以通过一定的方式运行在一个进程空间中。
- 一个Activity应用启动后至少会有3个线程：即一个主线程和两个Binder线程。

5.2 Handler，MessageQueue，Runnable与Looper

相信不少人对这几个概念“深恶痛绝”，因为它们“像雾像雨又像风”——自我感觉都很熟识，如果下一次再相遇，却又陌生得很。这种“隔靴搔痒”的感觉促使我们必须与这些“顽固分子”来个彻底的决断。

先不要想太多，任头脑中随意画一下对这些概念的第一印象，如图5-5所示。

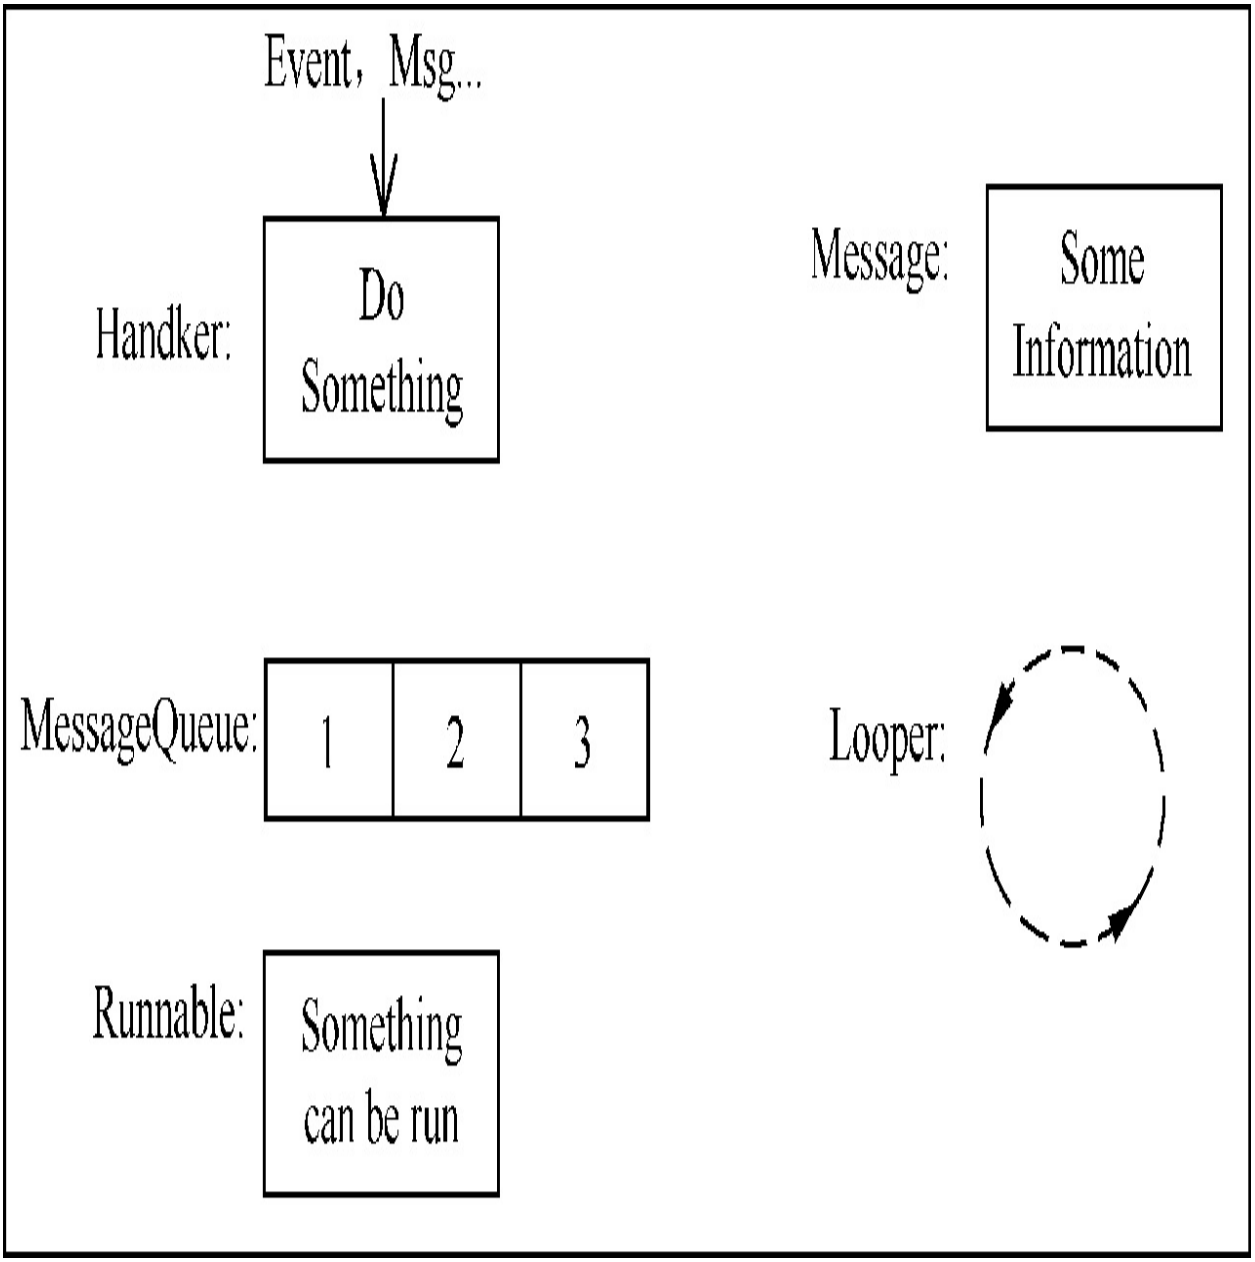

▲图5-5　概念初探

图5-5是我们对这几个概念的“感官”释义，读者可以尝试着思考下是否和自己所想的基本一致。

那么，如果把这些概念糅合在一起，又会是怎样的呢？如图5-6所示。

下面来解释图5-6的含义。

- Runnable和Message可以被压入某个MessageQueue中，形成一个集合

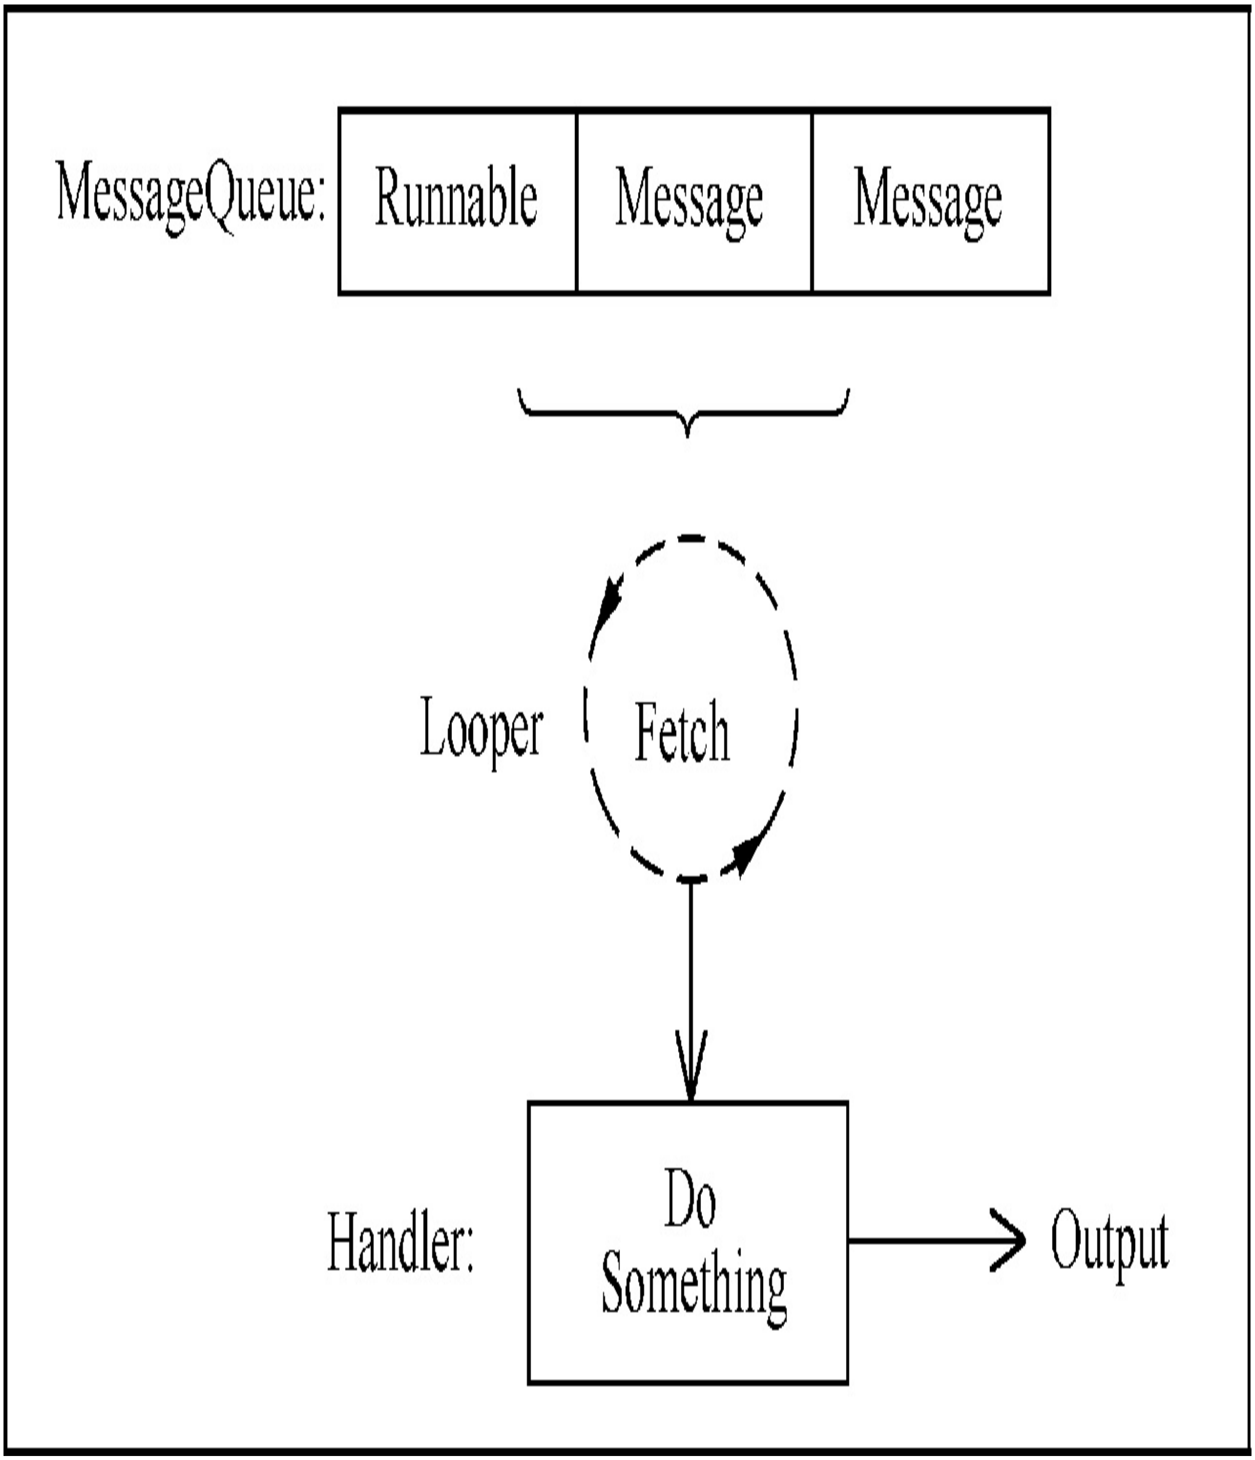

▲图5-6　Runnable，Message，MessageQueue，Looper和Handler的关系简图

注意，一般情况下某种类型的MessageQueue只允许保存相同类型的

Object。图中我们只是为了叙述方便才将它们混放在同一个MessageQueue中，实际源码中需要先对Runnalbe进行相应转换。

- Looper循环地去做某件事

比如在这个例子中，它不断地从MessageQueue中取出一个item，然后传给Handler进行处理，如此循环往复。假如队列为空，那么它会进入休眠。

- Handler是真正“处理事情”的地方

它利用自身的处理机制，对传入的各种Object进行相应的处理并产生最终结果。

用一句话来概括它们，就是：

Looper不断获取MessageQueue中的一个Message，然后由Handler来处理。

接下来的一系列分析无论多复杂，都是基于这句话展开的，希望读者牢记。

可以看出，上面的几个对象是缺一不可的。它们各司其职，很像一台计算机中CPU的工作方式：中央处理器（Looper）不断地从内存（MessageQueue）中读取指令（Message），执行指令（Handler），最终产生结果。当然，到目前为止我们还只是从逻辑的层面理清了它们的关系，接下来将从代码的角度来验证这些假设的真实可靠性。

1．Handler

代码路径：frameworks/base/core/java/android/os/Handler.java

读者有没有注意过，Handler和线程Thread是什么关系：

```
public class Handler {…
    final MessageQueue mQueue;
    final Looper mLooper;
    final Callback mCallback;
```

本小节中几个主要元素的类关系如图5-7所示。

从图中可以看出，Handler和Thread确实没有在表象上产生直接的联系。但是因为：

① 每个Thread只对应一个Looper；

② 每个Looper只对应一个MessageQueue；

③ 每个MessageQueue中有N个Message；

④ 每个Message中最多指定一个Handler来处理事件。

由此可以推断出，Thread和Handler是一对多的关系。

Handler是应用开发人员经常会使用到的一个类。概言之，它有两个方面的作用。

- 处理Message，这是它作为“处理者”的本职所在。
- 将某个Message压入MessageQueue中。

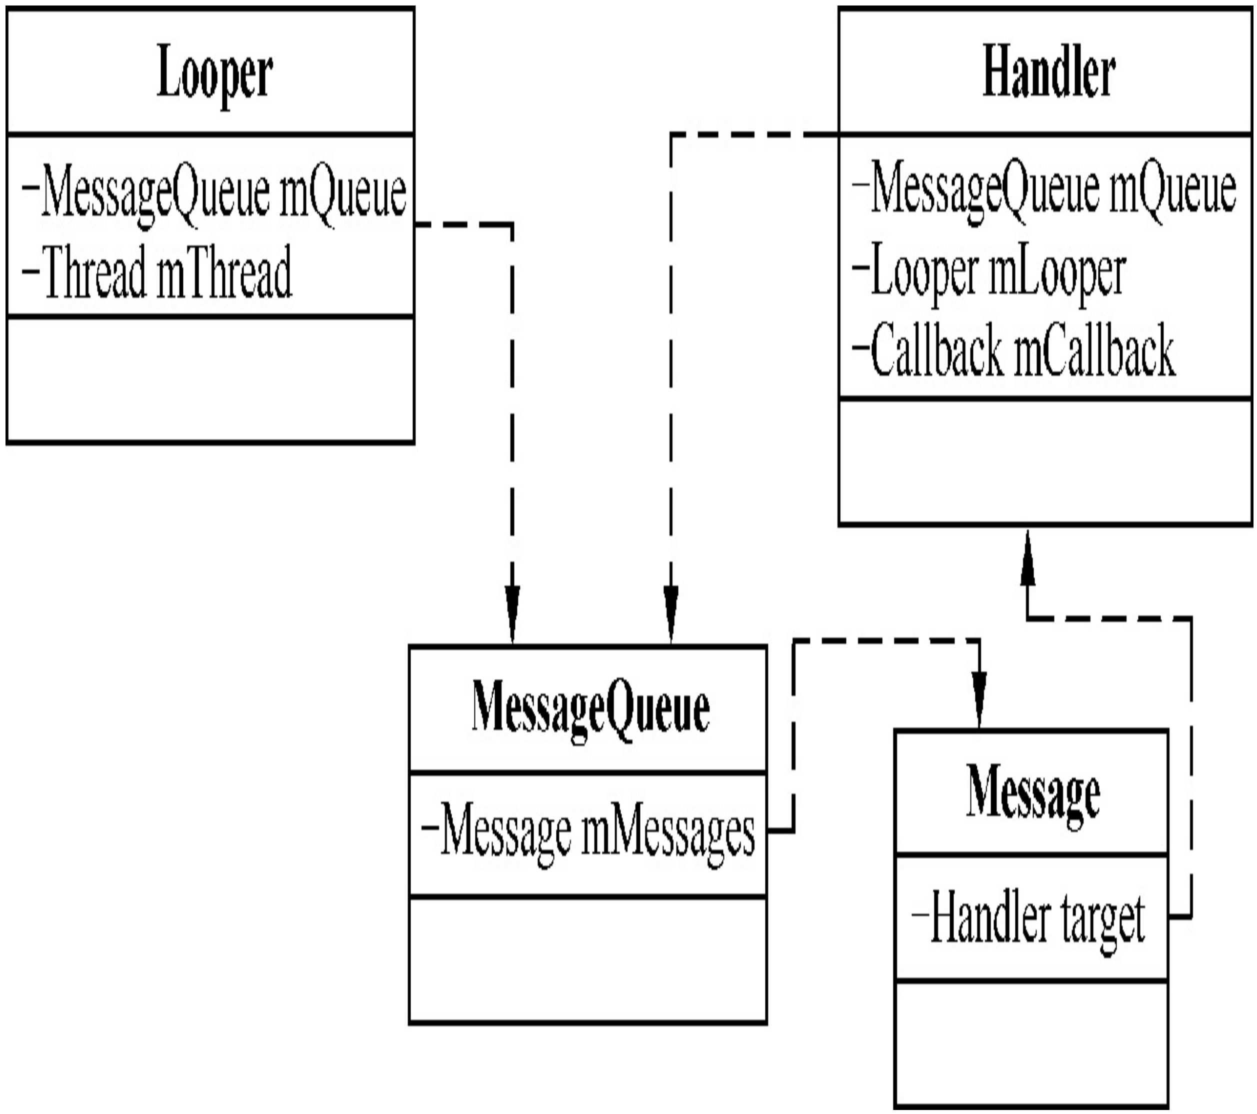

▲图5-7　Thread和Handler的关系图

实现第一个功能的相应函数声明如下：

```
public void dispatchMessage(Message msg);//对Message进行分发
public void handleMessage(Message msg);//对Message进行处理
```

Looper从MessageQueue中取出一个Message后，首先会调用Handler.dispatchMessage进行消息派发；后者则根据具体的策略来将Message分发给相应的责任人。默认情况下Handler的派发流程是：

```
Message.callback(Runnable对象)是否为空
```

在不为空的情况下，将优先通过callback来处理。

Handler. mCallback是否为空

在不为空的情况下，调用mCallback.handleMessage。

如果前两个对象都不存在，才调用Handler.handleMessage

由此可见，Handler的扩展子类可以通过重载dispatchMessage或者handleMessage来改变它的默认行为。具体选择何种方式取决于项目的实际需求。

Handler的第二个功能是容易引起开发人员困惑之所在，因为这样的设计形成了Handler MessageQueueMessageHandler的“循环圈”（见图5-7）。

相应的功能函数声明如下：

```
1.  Post系列：
final boolean post(Runnable r);
final boolean postAtTime(Runnable r, long uptimeMillis);
…
2.  Send系列：
final boolean      sendEmptyMessage(int what);
final boolean      sendMessageAtFrontOfQueue(Message msg);
boolean     sendMessageAtTime(Message msg, long uptimeMillis);
final boolean      sendMessageDelayed(Message msg, long delayMill
```

Post和Send两个系列的共同点是它们都负责将某个消息压入MessageQueue中；区别在于后者处理的函数参数直接是Message，而Post则需要先把其他类型的“零散”信息转换成Message，再调用Send系列函数来执行下一步。

我们只挑选第一个Post函数来分析源码，其逻辑流程如图5-8所示。

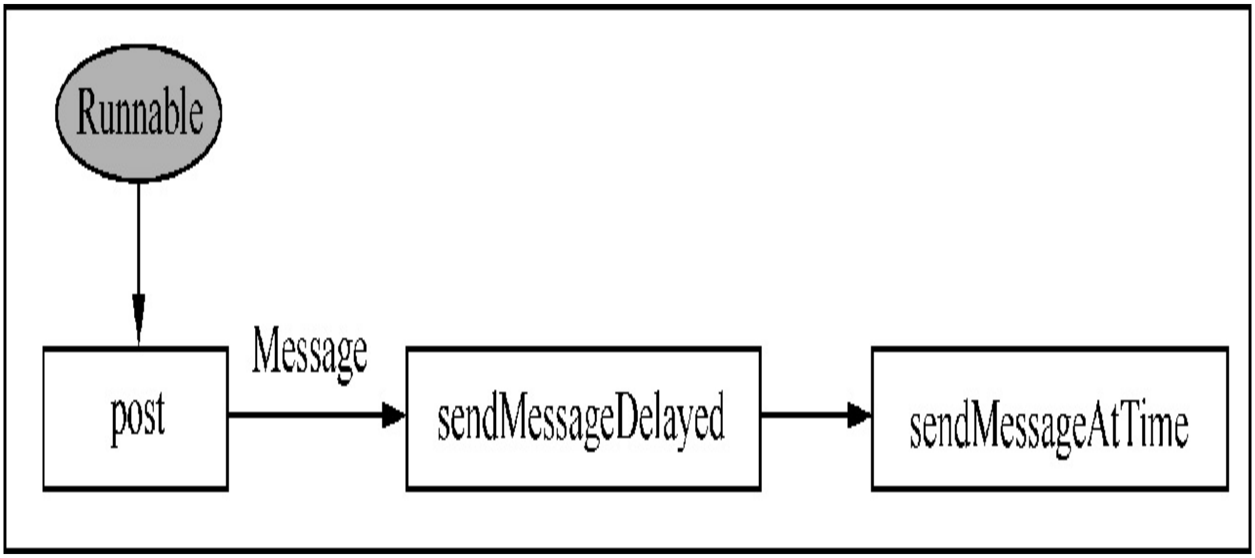

▲图5-8　post()的调用逻辑

```
public final boolean post(Runnable r)
{
   return  sendMessageDelayed(<strong>getPostMessage(r)</stro
}
```

因为调用者提供的是Runnable对象，post需要先将其封装成一个Message，接着通过对应的send函数把它推送到MessageQueue中：

```
private static Message getPostMessage(Runnable r) {
    Message m = Message.obtain(); /*Android系统会维护一个全局的Me
   用Message时，可以通过obtain直接获得，而不是自行创建。这样的设计可以
    m.callback = r;/*将Runnable对象设置为Message的回调函数*/
    return m;
}
```

当准备好Message后，程序调用sendMessageDelayed来执行下一步操作。这个函数可以设定延迟多长时间后再发送消息，其内部又通过当前时间+延时时长计算出具体是在哪个时间点（sendMessageAtTime）发送消息。

sendMessageAtTime函数的源码如下：

```
public boolean sendMessageAtTime(Message msg, long uptimeMill
    MessageQueue queue = mQueue;/*Handler对应的消息队列*/
    if (queue == null) {/*正常情况下，每个Thread都会有一个MessageQ
                        除非发生了意外queue才会为空*/
```

```
            RuntimeException e = new RuntimeException(
                    this + " sendMessageAtTime() called with no m
            Log.w("Looper", e.getMessage(), e);
            return false;
        }
        return enqueueMessage(queue, msg, uptimeMillis);/*将这个消
    }
```

这样我们就将一条由Runnable组成的Message通过Handler成功地压入了MessageQueue中。读者可能会觉得很奇怪，最终仍然是依靠Handler来处理这一消息的，为什么它不直接执行操作，而是大费周折地先把Message压入MessageQueue中，然后再处理呢？这其实体现了程序设计一个良好的习惯，即“有序性”。

比如某天你和朋友去健身房运动，正当你在跑步机上气喘吁吁时，旁边有个朋友跟你说：“哥们，最近手头紧，借点钱花花。”那么这时候你就有两个选择：

- 马上执行

这就意味着你要从跑步机上下来，问清借多少钱，然后马上打开电脑进行网上转账。

- 稍后执行

上面的方法在某些场合下是有用且必需的——比如你的朋友等着这笔钱急用。不过大部分情况下“借钱”这种事并不是刻不容缓的，因而你可以跟朋友说：“借钱没问题，你先和我秘书约时间，改天我们具体谈细节。”那么在这种情况下，“借钱事件”就先通过秘书写入了MessageQueue进行排队。这意味着你并不需要马上从跑步机上下来，中断愉悦的健身运动。

之后秘书会一件件通知你MessageQueue上的待办事宜（当然你也可以主动问秘书），直到某个Message上标明“借钱事件”时才需要和这位朋友做进一步商谈。在一些场合下这样的处理方式是合情合理的。比如说健身房一小时花费是10万元，而你朋友只借100元，那么显然“借钱事件”优先级较小，排队处理就是必要的。

下面以框图的形式来加深大家的理解，如图5-9所示。

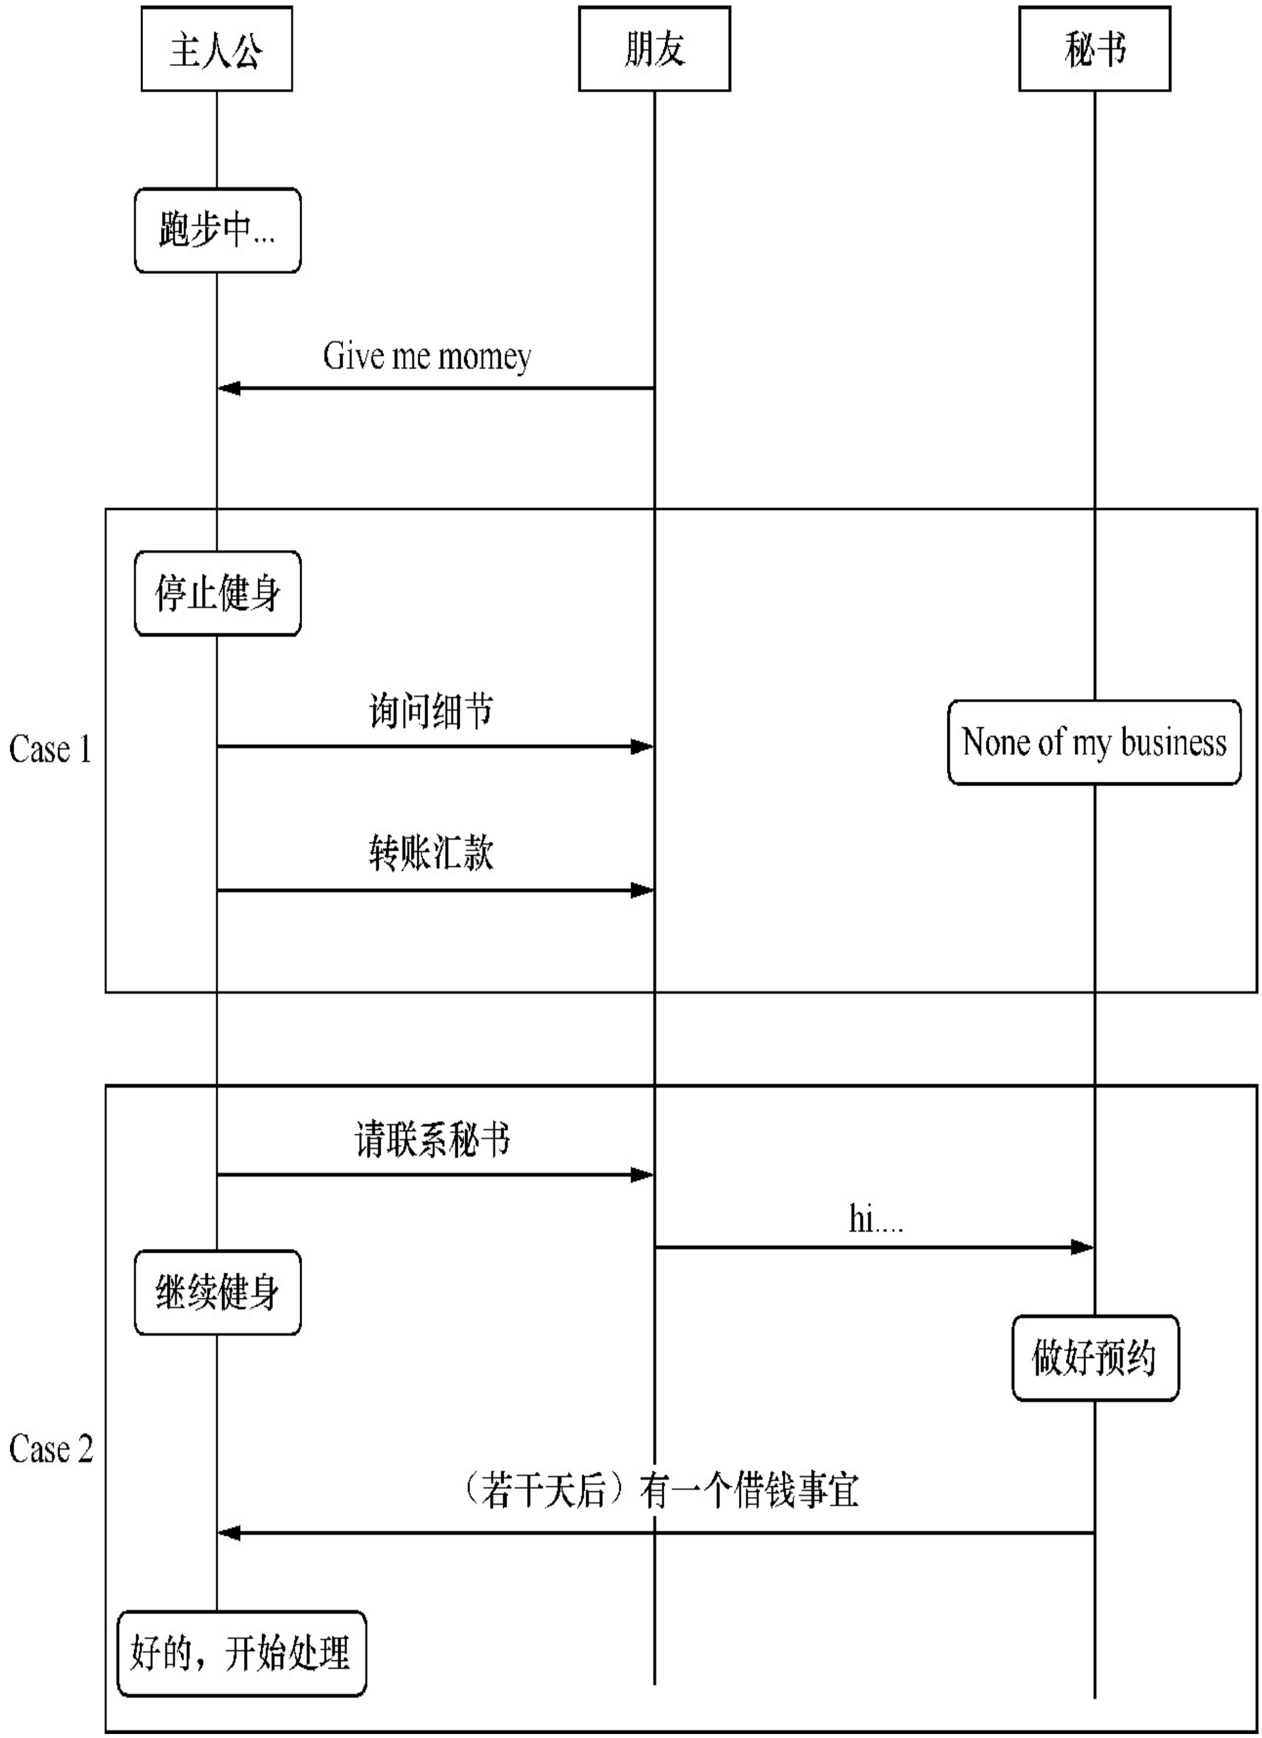
主人公
朋友
秘书
跑步中...
Give me momey
停止健身
询问细节
None of my business
Case 1
转账汇款
请联系秘书
hi....
继续健身
做好预约
Case 2
（若干天后）有一个借钱事宜
好的，开始处理

▲图5-9　两种消息处理方式类比

2．MessageQueue

源码路径：frameworks/base/core/java/android/os。

MessageQueue正如其名，是一个消息队列，因而它具有“队列”的所有常规操作。包括：

- 新建队列

由其构造函数和本地方法nativeInit组成。

其中，nativeInit会在本地创建一个NativeMessageQueue对象，然后直接赋给MessageQueue中的成员变量。这一系列的操作实际上都是通过内存指针进行的，详见本书JNI章节的描述。

- 元素入队

```
final boolean enqueueMessage(Message msg, long when);
```

- 元素出队

```
final Message next();
```

- 删除元素

```
final void removeMessages(Handler h, int what, Object
object);

final void removeMessages(Handler h, Runnable r, Object
object);
```

- 销毁队列

和创建过程一样，也是通过本地函数nativeDestroy来销毁一个MessageQueue。

整个MessageQueue类的源码数量不多，也并不难理解，这里先不做深入分析。接下来涉及MessageQueue的具体应用场景时，我们再有重点地进行了解。

3．Looper

源码路径：frameworks/base/core/java/android/os。

Looper有点类似于发动机——正是由于它的推动，Handler甚至整个程序才成为活源之水，不断地处理新的消息。

还记得前面我们将Handler、MessageQueue、Looper等概念糅合在一起组合成的那个“大脑印象图”吗？实际上它们在Android系统中的源码实现和这个图是比较接近的，只不过还需要做一点修改，如图5-10所示。

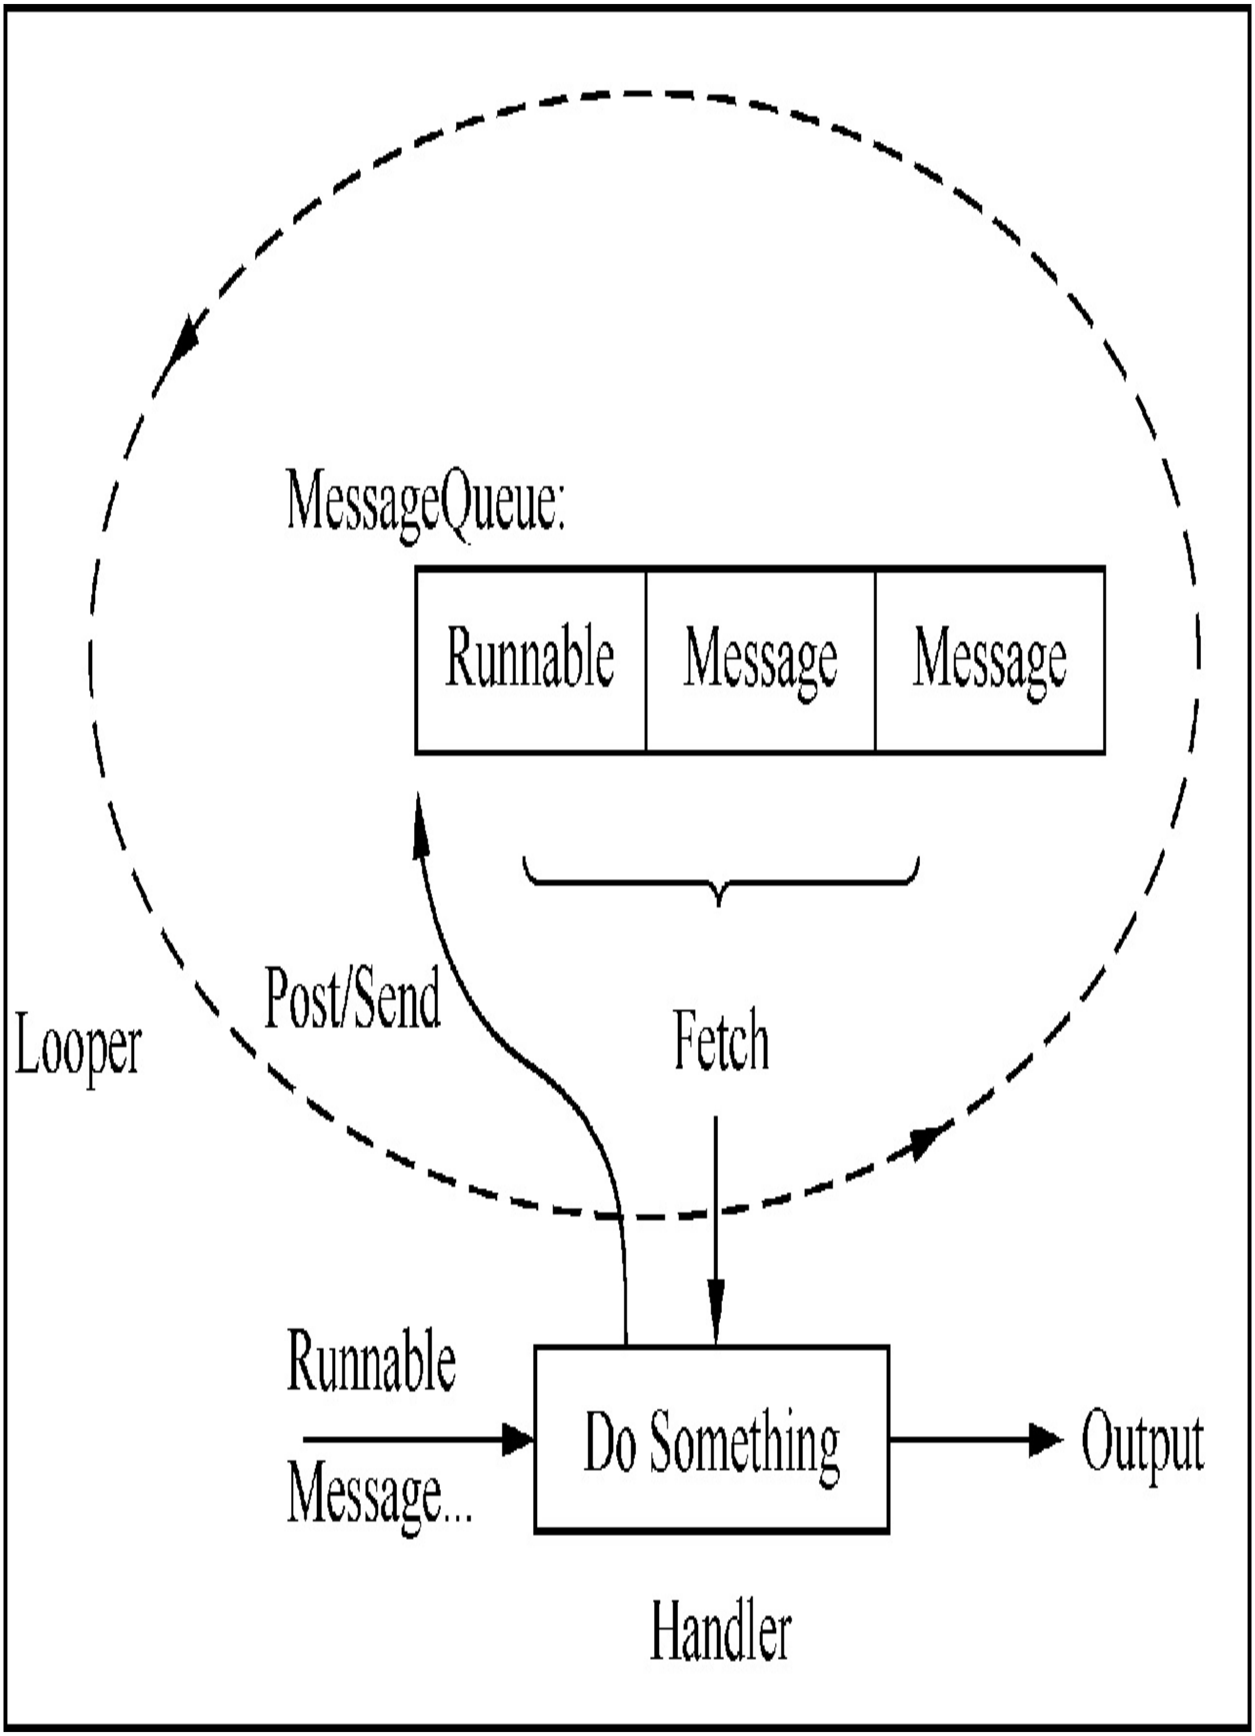
MessageQueue:
Runnable
Message
Message
Looper
Post/Send
Fetch
Runnable
Message...
Do Something
Output
Handler

▲图5-10　更贴近Android实现的“印象图”

图中传达了一个信息，即Looper中包含了一个MessageQueue。因此，整个框图就只剩下Looper和Handler（还有多数情况下隐藏得很深的Thread）之间的关系了。

应用程序使用Looper分为两种情况。

- 主线程（MainThread）

也就是ActivityThread，下一小节有详细介绍。

- 普通线程

下面是一个使用Looper的普通线程范例，名为LooperThread：

```
class LooperThread extends Thread {
    public Handler mHandler;
    public void run() {
        Looper.prepare();/*一句简单的prepare，究竟做了些什么工作？*/
        mHandler = new Handler() {
            public void handleMessage(Message msg) {
             …/*处理消息的地方。继承Handler的子类通常需要修改这个函数*/
            }
        };
        Looper.loop();/*进入主循环*/
    }
}
```

这段代码在Android线程中很有典型意义。概括起来只有3个步骤：

（1）Looper的准备工作（prepare）；

（2）创建处理消息的handler；

（3）Looper开始运作（loop）。

虽然代码给人的感觉非常简洁，不过乍一看仍有不少地方难以理解。比如整个过程我们都没有看到Looper对象的创建，程序最后也只是调用了Looper.loop，整个系统的循环消息处理机制就“跑”起来了。

另外，mHandler是如何保证把外部的消息投递到Looper所管理的MessageQueue中的，或者说Looper和Handler之间有何隐藏的联系呢？

下面结合上面那段LooperThread代码，来逐一品味Android呈现出的这一台好戏。

首先是：

```
Looper.prepare();
```

既然要使用Looper类的函数，那么LooperThread中肯定就得执行如下操作：

```
import android.os.Looper;
```

仔细观察，Looper里有个非常重要的成员变量：

```
static final ThreadLocal<Looper> sThreadLocal = new ThreadLocal<L
```

这是一个静态类型的变量，意味着一旦import了Looper后，sThreadLocal就已经存在并构建完毕。ThreadLocal对象是一种特殊的全局变量，因为它的"全局"性只限于自己所在的线程，而外界所有线程（即便是同一进程）一概无法访问到它。这从侧面告诉我们，每个线程的Looper都是独立的。

可以猜想下，虽然Looper提供了若干static的成员函数以方便开发者进行调用，但是它们毕竟只代表了"公共的行为"，其内部一定还需要有针对每个Thread的特定数据存储空间。举个例子，Looper中的这些static操作有点类似于银行的普通业务服务窗口，它并不指定任何特定的客户，但是去办理业务的人却又是完全可以区分开来的。为什么呢？因为大家手头都会持有反映自己身份的各种证件和申请表格——sThreadLocal。

因而sThreadLocal肯定会创建一个只针对当前线程的Looper及其他相关的数据对象，而且这个操作很可能是在prepare（Looper总共就两行，这个就很明显了）中。下面来验证一下是不是这样的：

```
    private static void prepare(boolean quitAllowed) {
       if (sThreadLocal.get() != null) {/*sThreadLocal.get返回的是
                                           这个判断保证一个Thread只会有一
```

```
            throw new RuntimeException("Only one Looper may be cre
        }
        sThreadLocal.<strong>set</strong>(new Looper(quitAllowed)
    }
```

上面的最后一个语句验证了我们的猜想：sThreadLocal的确保存了一个新创建的Looper对象。其实sThreadLocal这个名字取得不太好，容易引起误解。如果改成sThreadLocalData，估计大家就能看得更明白些了；而且它还是一个模板类，这就说明它并不存储特定类型的数据，而是任何你感兴趣的东西都可以——出租的是“柜子”，而不是“鞋柜”。

接下来创建一个Handler对象，我们单独将它提取出来以方便阅读。

```
public Handler mHandler;
…
mHandler = new Handler() {
     public void handleMessage(Message msg) {…
     }
};
```

可见，mHandler是LooperThread的成员变量，并通过new操作创建了一个Handler实例。仅从这两行代码来看，并没有什么蹊跷的地方。那么，Handler到底是如何与Looper关联起来的呢？没错，就是构造函数。

Handler有多个构造函数，比如：

```
public Handler();
public Handler(Callback callback);
public Handler(Looper looper);
public Handler(Looper looper, Callback callback);
```

之所以有这么多构造函数，是因为Handler有如下内部变量需要初始化：

```
final MessageQueue mQueue;
    final Looper mLooper;
    final Callback mCallback;
```

我们就以LooperThread例子中采用的第一个函数来讲解下它的构造

函数：

```
public Handler() {
     /*…省略部分代码*/
     mLooper =Looper.myLooper();/*还是通过sThreadLocal.get来获取当前
     …
<strong>     mQueue </strong>= mLooper.mQueue; /*mQueue是Looper与H
      mCallback = null;
}
```

这样Handler和Looper，MessageQueue就联系起来了。后续Handler执行Post/Send两个系列的函数时，会将消息投递到mQueue也就是mLooper.mQueue中。一旦Looper处理到这一消息，它又会从中调用Handler来进行处理。

到目前为止，代码就只剩下最后的一句Looper.loop()了。因为和ActivityThread中的内容有重叠，我们统一放在下一小节讲解。

5.3 UI主线程——ActivityThread

前面我们对MessageQueue等几个重要概念进行了串讲，相信读者已对它们有了一定的认识。这一小节将接着上面还没有解决的问题做进一步分析。因为LooperThread例子只是一个“壳”，也就是说它让我们非常清楚地看到Android典型线程里的架构，却没有真正可以运行的“内容”。所以要回答剩余的两个问题，ActivityThread是一个很好的示例。从名称上看，它是Activity所属的线程，也就是大家熟悉的UI主线程：

```
/*frameworks/base/core/java/android/app/ActivityThread.java*
public static void main(String[] args) {
   …
   Looper.prepareMainLooper();//和前面的LooperThread不同
   ActivityThread thread = new ActivityThread();//新建一个Act:
   thread.attach(false);
   if (sMainThreadHandler == null) {
       sMainThreadHandler = thread.getHandler();//主Handler
   }
   AsyncTask.init();
   Looper.loop();
   throw new RuntimeException("Main thread loop unexpectedly
 }
```

如果注意比较上面这段代码与LooperThread.run()的实现，就可以发现它们在整体架构上是一致的。区别主要体现在：

- prepareMainLooper和prepare

普通线程只要prepare就可以了，而主线程使用的是prepareMainLooper。

- Handler不同

普通线程生成一个与Looper绑定的Handler对象就行，而主线程是从当前线程中获取的Handler（thread.getHandler）。

（1）那么，prepareMainLooper有什么特殊之处呢？

```
/*frameworks/base/core/java/android/os/Looper.java*/
```

```
public static void prepareMainLooper() {
  prepare(false);//先调用prepare
  synchronized (Looper.class) {
     if (sMainLooper != null) {
         throw new IllegalStateException("The main Looper ha
     }
     sMainLooper = myLooper();
  }
}
```

可以看到，prepareMainLooper也需要用到prepare。参数false表示该线程不允许退出，这和前面的LooperThread不一样。经过prepare后，myLooper就可以得到一个本地线程<ThreadLocal>的Looper对象，然后将其赋给sMainLooper。从这个角度来讲，主线程的sMainLooper其实和其他线程的Looper对象并没有本质的区别。

是不是觉得有点理不清思路？图5-11应该会对你有所帮助。

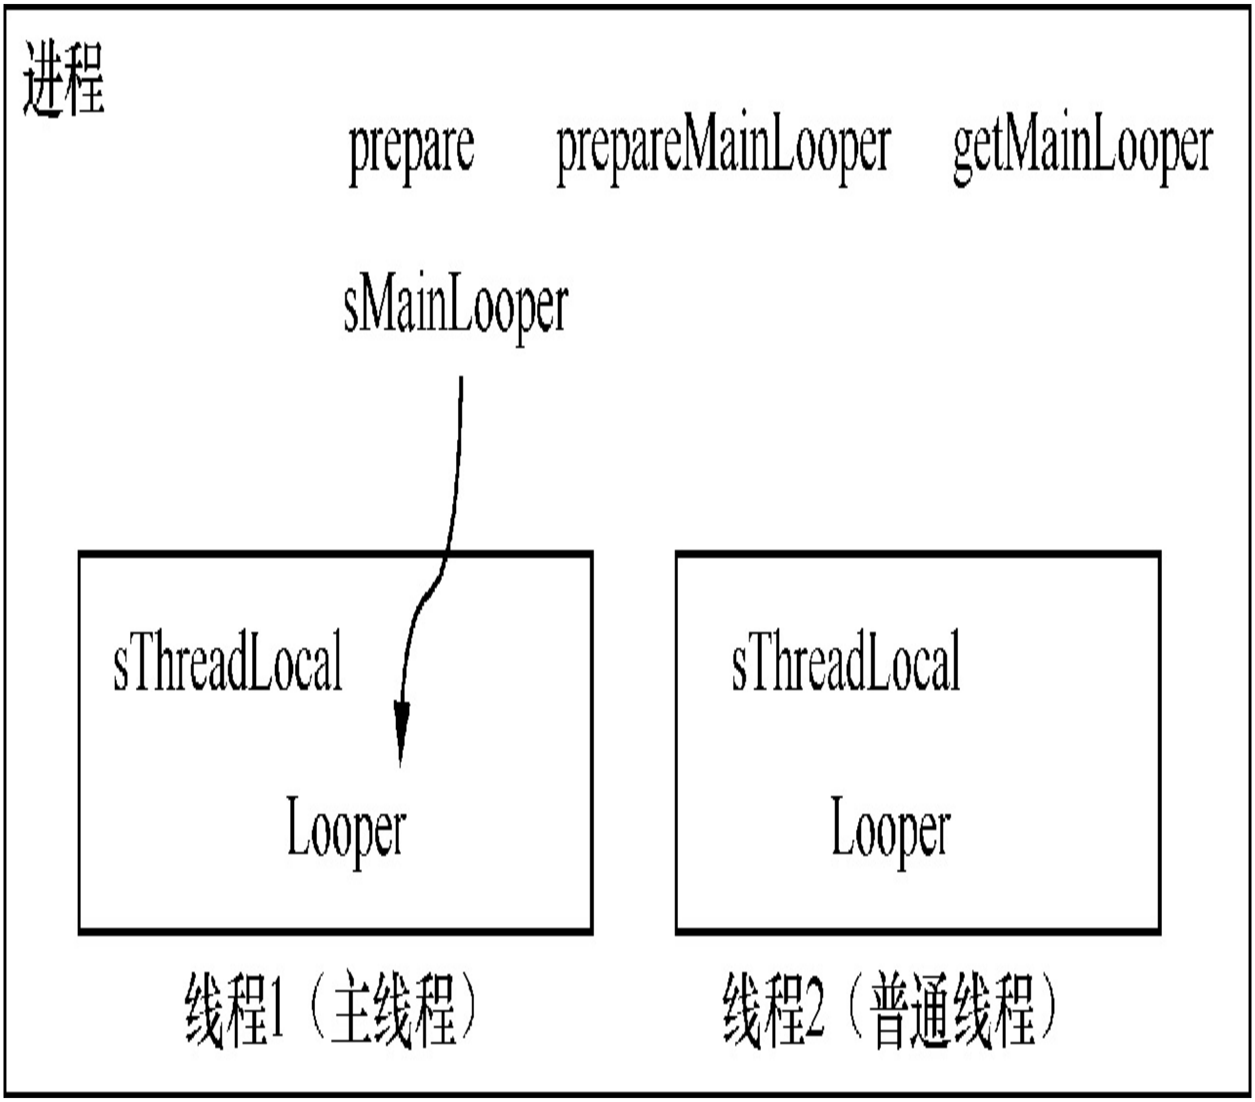

▲图5-11　Looper揭密

这个图描述的是一个进程和它内部两个线程的Looper情况，其中线程1是主线程，线程2是普通线程。方框表示它们能访问的范围，如线程1就不能直接访问到线程2中的Looper对象，但二者都可以接触到进程中的各元素。

线程1：因为是Main Thread，它使用的是prepareMainLooper()，这个函数将通过prepare()为线程1生成一个ThreadLocal的Looper对象，并让sMainLooper指向它。这样做的目的就是其他线程如果要获取主线程的Looper，只需调用getMainLooper()即可。

线程2：作为普通线程，它调用的是prepare()；同时也生成了一个

ThreadLocal的Looper对象，只不过这个对象只能在线程内通过myLooper()访问。当然，主线程内部也可以通过这个函数访问它的Looper对象。

由此可见，Google玩了一个小技巧，从而巧妙地区分开各线程的Looper，并界定了它们的访问权限。

（2）sMainThreadHandler。当ActivityThread对象创建时，会在内部同时生成一个继承自Handler的H对象：

```
final H mH = new H();
```

ActivityThread.main中调用的thread.getHandler()返回的就是mH。

也就是说，ActivityThread提供了一个“事件管家”，以处理主线程中的各种消息。

接下来我们分析下loop()函数，不过在此之前还需要了解点基础知识。本章的开头曾简单提到了main函数，它的经典模型用伪代码表示（以Windows下的图形程序开发为例）如下：

```
main()
{
    initialize(); //初始化操作
    CreateWindow();//创建窗口
    ShowWindow();//显示窗口
    while(GetMessage()) //不断地获取并执行消息，直至收到退出的消息
    {
        TranslateMessage(); //对消息进行必要的前期处理
        DispatchMessage(); //分配消息给相应元素进行处理
    }
}
```

这个模型在每个系统平台上的实现细节会有所差异，但本质都是一样的。概括起来重点只有两个：

- 创建处理消息的环境；
- 循环处理消息。

也就是说，消息是推动整个系统动起来的基础，即便操作系统本身

也是如此。

有了这个前提，我们再回过头来看Android中Looper.loop的实现：

```
public static void loop() {
  final Looper me = myLooper();/*loop函数也是静态的，所以它只能访问
                              则调用sThreadLocal.get()来获取与之匹
                              就是取出之前prepare中创建的那个Looper
  …
  final MessageQueue queue = me.mQueue;/*正如我们之前所说，Loope
  …
  for (;;) {//消息循环开始
      Message msg = queue.next();/*从MessageQueue中取出一个消息，
      if (msg == null) {/*如果当前消息队列中没有msg，说明线程要退出
                     伪代码例子中的while判断条件为0，这样就会结束循环
          return; /*直接返回，结束程序*/
      }
    …
      msg.target.dispatchMessage(msg); /*终于开始分派消息了，重心
              实是一个Handler，所以dispatchMessage最终调用的是Hand
      …
      msg.recycle();/*消息处理完毕，进行回收*/
  }
}
```

可以看到，loop()函数的主要工作就是不断地从消息队列中取出需要处理的事件，然后分发给相应的责任人。如果消息队列为空，它很可能会进入睡眠以让出CPU资源。而在具体事件的处理过程中，程序会post新的事件到队列中。另外，其他进程也可能投递新的事件到这个队列中。APK应用程序就是不停地执行“处理队列事件”的工作，直到它退出运行，如图5-12所示。

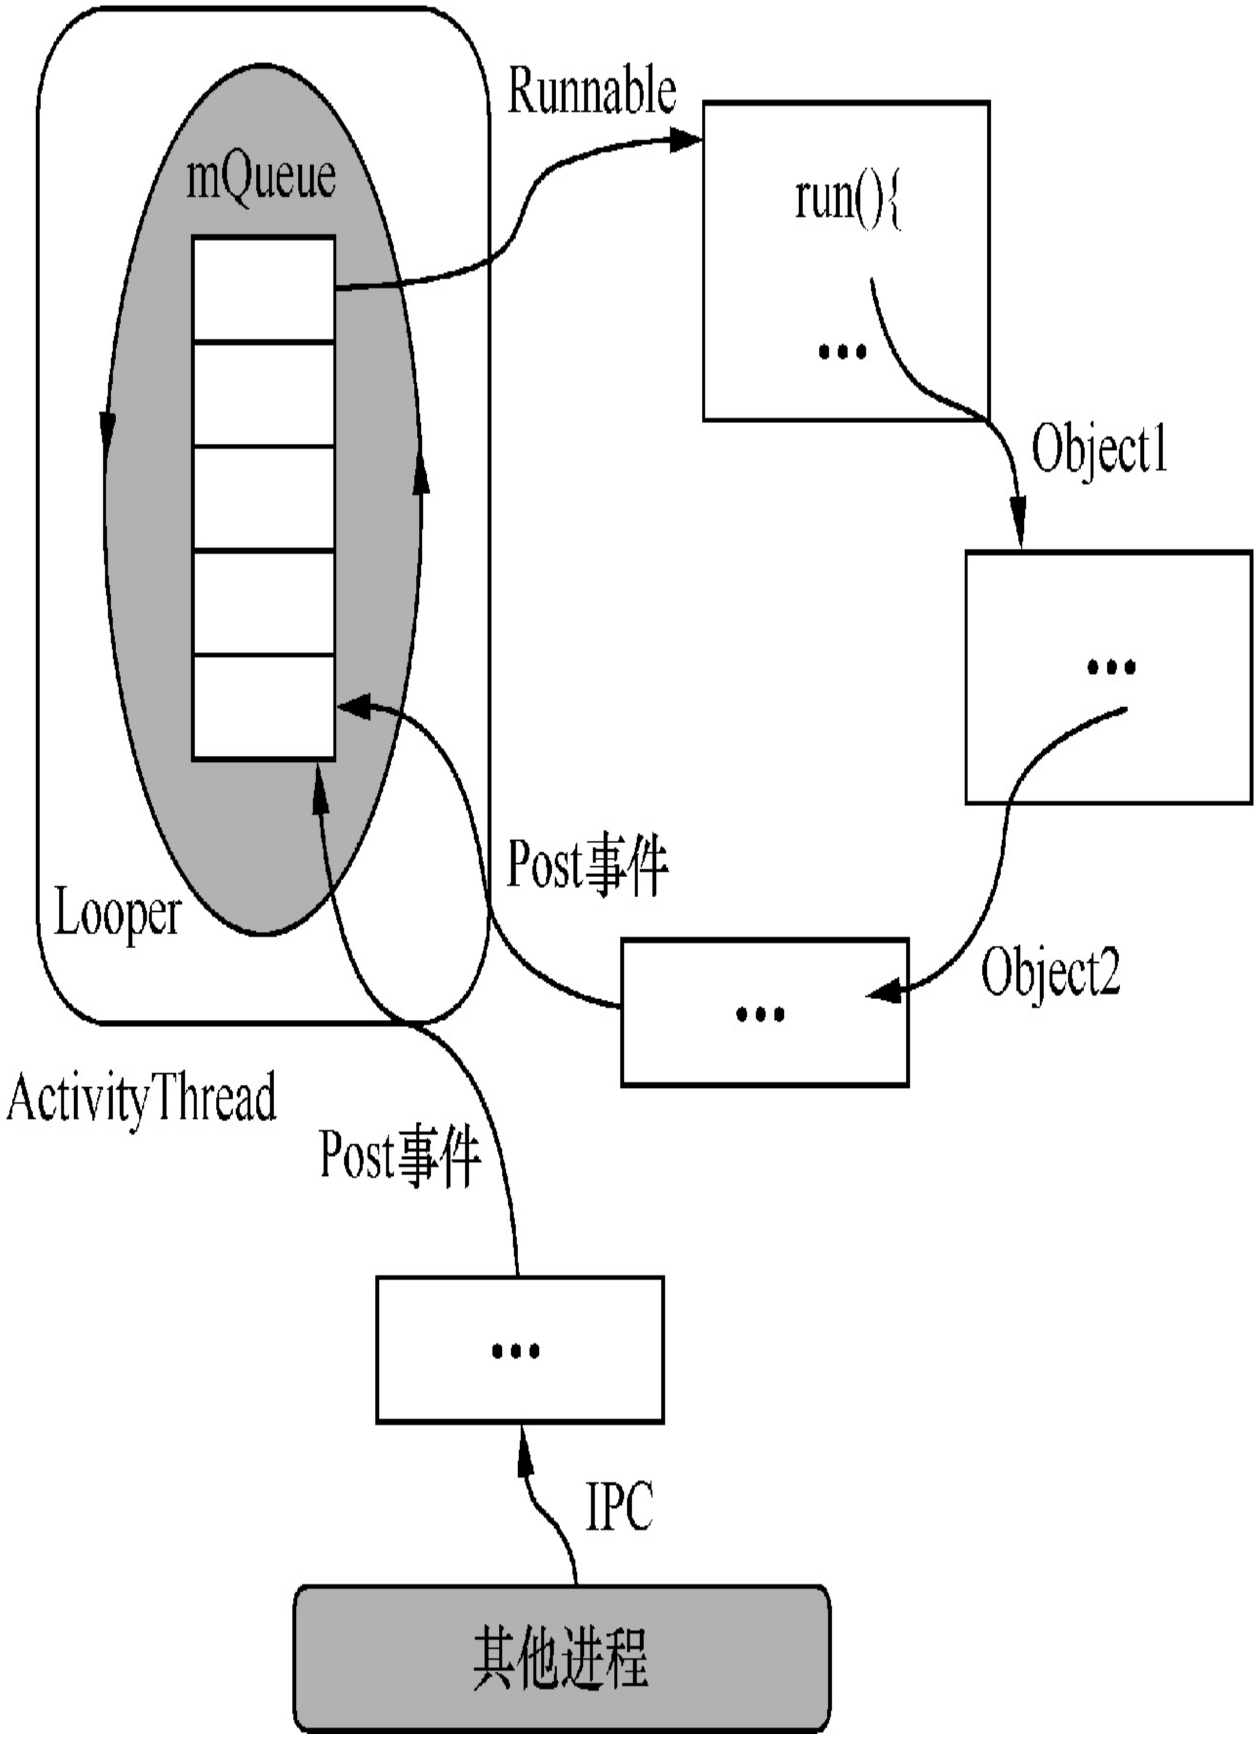
Runnable
mQueue
run(){
...
Object1
...
Post事件
Looper
Object2
...
ActivityThread
Post事件
...
IPC
其他进程

▲图5-12　基于ActivityThread的进程模型

在这个模型图中，ActivityThread这个主线程从消息队列中取出Message后，调用它对应的Runnable.run进行具体的事件处理。在处理的过程中，很可能还会涉及一系列其他类的调用（在图中用Object1，Object2表示）。而且它们可能还会向主循环投递新的事件来安排后续操作。另外，其他进程也同样可以通过IPC机制向这一进程的主循环发送新事件，如触摸事件、按键事件等。这就是APK应用程序能“动起来”的根本原因。

以上我们看到了Looper.loop的处理流程，从而知道它和前面讨论的Windows消息处理机制是类似的。最后再来解决一个问题：MessageQueue是怎么创建出来的？

我们说过，Looper中带有唯一一个MessageQueue，是不是这样的呢？

```
 /*以下代码还是Looper.java中的，不过只提取出MessageQueue相关的部分*/
final MessageQueue mQueue; /*注意它不是static的*/
private Looper(boolean quitAllowed) {
    mQueue = new MessageQueue(quitAllowed); /*new了一个Message
                                          也就是说，当Looper创建时，消息队列也
    mRun = true;
    mThread = Thread.currentThread();//Looper与当前线程建立对应关
}
```

事实证明Looper内部的确管理了一个MessageQueue，它将作为线程的消息存储仓库，配合Handler、Looper一起完成一系列操作。

5.4 Thread类

首先，提醒大家要正确地区分线程和线程类的概念。线程是操作系统CPU资源分配的调度单元，属于抽象的范畴；而线程类的本质仍是可执行代码，在Java中当然也就对应一个类。从这一点上看Thread和其他类并没有任何区别，只不过Thread的属性和方法仅用于完成“线程管理”这个任务而已。在Android系统中，我们经常需要启动一个新的线程，这些线程大多从Thread这个类继承。

5.4.1 Thread类的内部原理

```
/*libcore/libdvm/src/main/java/java/lang/Thread.java*/
public class Thread implements <strong>Runnable</strong> {
…
```

可以看到，Thread实现了Runnable，也就是说线程是“可执行的代码”：

```
/*libcore/luni/src/main/java/java/lang/Runnable.java*/
public interface Runnable {
   public void run();
}
```

Runnable是一个抽象接口类，唯一提供的方法就是run()。一般情况下，我们是这样使用Thread的：

- 方法1，继承自Thread

定义一个MyThread继承自Thread，重写它的run方法，然后调用：

```
MyThread thr = new MyThread(…);
thr.start();
```

- 方法2，直接实现Runnable

Thread的关键就是Runnable，因而下面是另一个常见用法：

```
new Thread(Runnable target).start();
```

这两种方法最终都通过start启动，它会间接调用上面的run实现。如下：

```
public synchronized void start() {
   checkNotStarted();
   hasBeenStarted = true;
   VMThread.<strong>create</strong>(this, stackSize);/*这里是真正创
}
```

在此之前，我们一直都运行在“老线程”中，直到VMThread.create——而实际上真正在新线程中运行的只有Run方法，这解释了上面第二种方法通过传入一个Runnable也可以奏效的原因。从这个角度来理解，Thread类只能算是一个中介，任务就是启动一个线程来运行用户指定的Runnable，而不管这个Runnable是否属于自身，如图5-13所示。

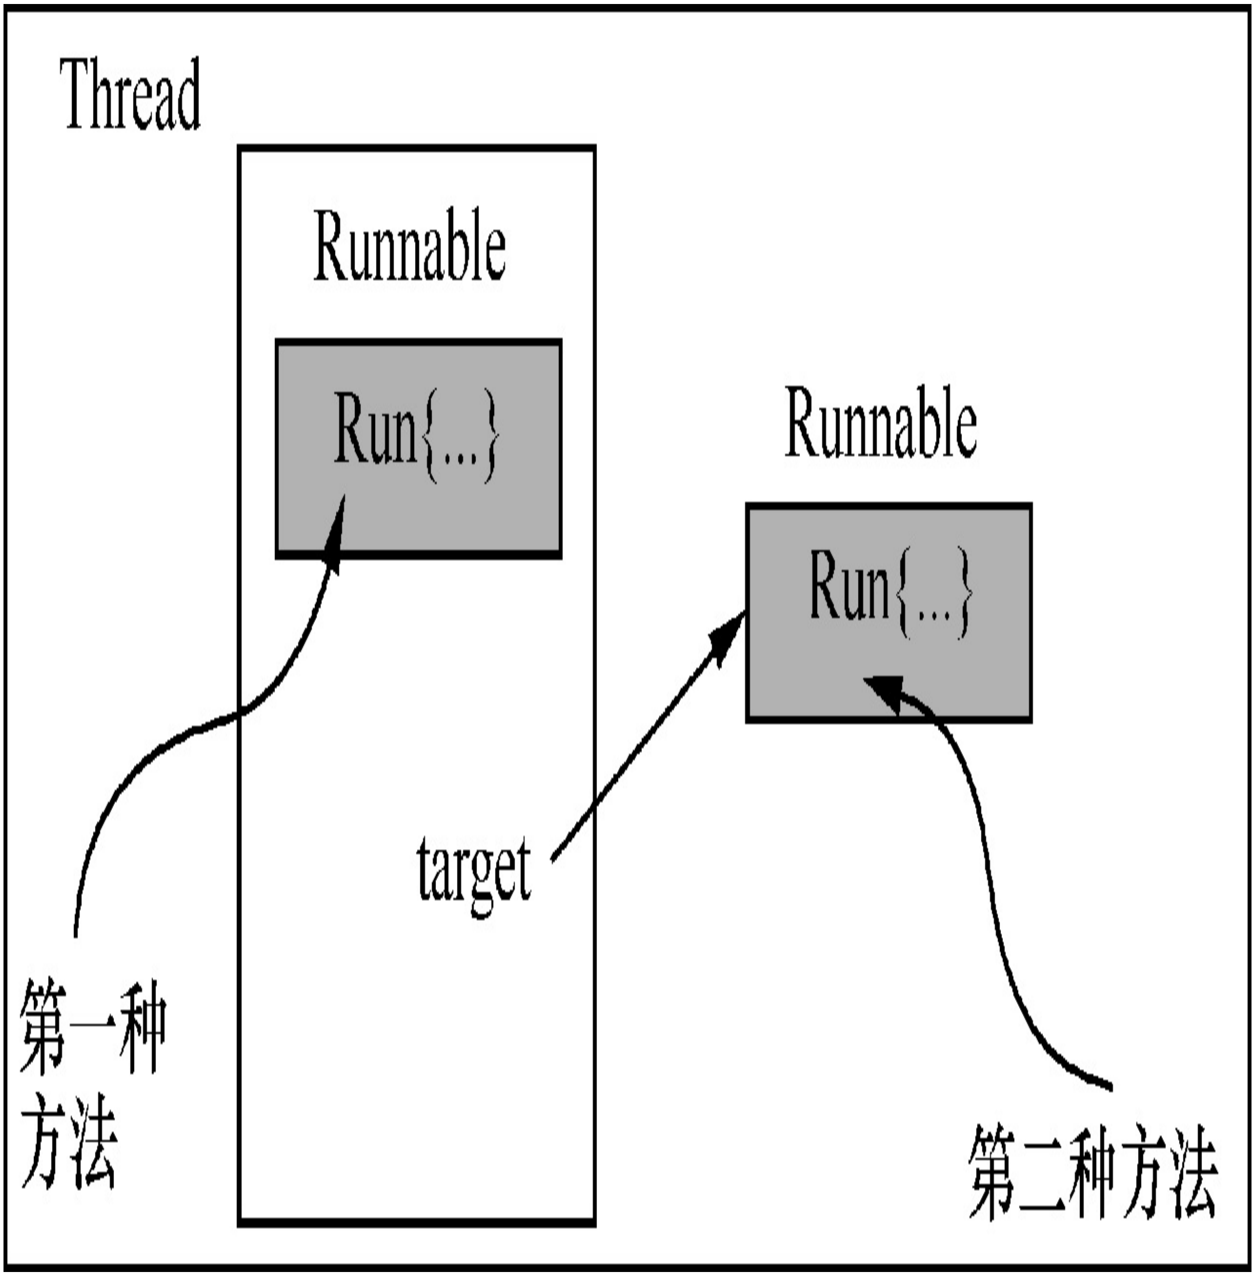

▲图5-13 创建Thread的两种方法

线程有如下几种状态：

```
public enum State {
   NEW, //线程已经创建，但还没有start
   RUNNABLE, //处于可运行状态，一切就绪
   BLOCKED, //处于阻塞状态，比如等待某个锁的释放
   WAITING, //处于等待状态
   TIMED_WAITING, //等待特定的时间
```

```
  TERMINATED //终止运行
}
```

5.4.2 Thread休眠和唤醒

休眠、等待以及激活唤醒是多线程编程非常重要的环节，也是令很多开发人员难以理解的地方。从逻辑上来讲，线程无非就是运行与不运行两种可能。但是因为不运行的原因有很多，运行的条件也不少，就使得我们不得不对它们进行细化，从而出现诸如休眠、等待、唤醒等一系列拗口的术语。

可以先来想一想线程中与此相关的控制方法都有哪些。

至少有：wait()、notify()、notifyAll()、interrupt()、join()和sleep()。

1. wait和notify/notifyAll

和其他接口方法不同，这3个函数是由Object类定义的——也就意味着它们是任何类的共有“属性”。那么，为什么要这么设计呢？

官方文档对wait的解释是：

"Causes the calling thread to wait until another thread calls the

我们以WindowManagerService中的一段代码作为例子来讲解：

```
/*frameworks/base/services/java/com/android/server/SystemServer.j
HandlerThread wmHandlerThread = new HandlerThread("WindowManager"
       wmHandlerThread.start();/*启动线程*/
       Handler wmHandler = new Handler(wmHandlerThread.getLooper(
                                              wmHandlerThread 中
       wmHandler.post(new Runnable() {
          @Override
          public void run() {
             android.os.Process.setThreadPriority(android.os.Proc
             android.os.Process.setCanSelfBackground(false);
               …
          }
      });
```

上面这段代码的主要目的是启动一个HandlerThread，并由

wmHandler变量post一个Runnable给它，以完成线程优先级等参数的设置。当SystemServer调用WindowManagerService的main函数时，将传入wmHandler参数，具体如下所示：

```
/*frameworks/base/services/java/com/android/server/wm/WindowManag
   public  static WindowManagerService main(final Context context
                     final DisplayManagerService dm, final InputMa
                     final Handler uiHandler, final Handler wmHand
           final boolean haveInputMethods,final boolean showBootMs
       final WindowManagerService[] holder = new WindowManagerServ
       wmHandler.runWithScissors(new Runnable() {
           @Override
           public void run() {
              holder[0] = new WindowManagerService(context, pm, dm
                     uiHandler, haveInputMethods, showBootMsgs, on
           }
       }, 0);
       return holder[0];
   }
```

这个main函数的核心是runWithScissors，注意此时CPU仍然运行于SystemServer所在的线程中。根据代码注释，runWithScissors虽然是Handler.java中的方法，但并没有在SDK中提供；而且有意思的是源码作者自己也认为函数名取得不是很恰当，如果要对外发布最好改为runUnsafe()。

下面来分析下它的作用：

```
   public final boolean runWithScissors(final Runnable r, long ti
       …
       if (Looper.myLooper() == mLooper) {/*当前线程的Looper和Handle
           r.run();/*是的话直接执行Runnable，返回true*/
           return true;
       }
       BlockingRunnable br = new <strong>BlockingRunnable</strong>
       return br.<strong>postAndWait</strong>(this, timeout);
   }
```

前面说过，runWithScissors还是在SystemServer这个线程运行的，所以Looper.myLooper() != mLooper。这也意味着程序接下来将涉及线程等待，具体实现在postAndWait中，它所属的类是BlockingRunnable：

```
public boolean postAndWait(Handler handler, long timeout) {
    if (!handler.post(this)) {/*投递Runnable到Handler所属的Loo
       return false;
    }
    /*如果成功投递，接下来就需要等待了*/
    synchronized (this) {
       if (timeout > 0) {//如果等待是有时间限制的话
          ..//在本场景中，WindowManagerService传入的值为0，所以不
       } else {//如果需要无限期等待的话
          while (!mDone) {
             try {
              wait();/*走过千山万水后，主角终于出现了*/
             } catch (InterruptedException ex) {
             }
          }
       }
     }
     return true;
 }
```

WindowManagerService中关于“线程等待”的这一段代码在多个Android版本中改动很大。个人认为Android 4.3中的写法并不是太好，可读性也一般，不如Android 4.1中的做法来得简洁高效。从函数本身的注解来看，开发人员似乎只是把这一改动当成一种试验，相信后续版本还会有更好的解决方案。

函数postAndWait在Handler中起到的作用就是“投递并等待”。所以函数一开头就把一个Runnable（即this）post到handler所在Looper中去，大家应该能想到这个handler还是wmHandler。接着分为两种情况：

- timeout大于0

说明调用者希望是有条件限制的等待，即当timeup时会被认为出错，直接返回。这样做的目的是避免异常情况下的“死等待”。不过对于WindowManagerService这类系统关键组件，如果它运行不正常整个设备也就基本上“GameOver”了。所以这里的传值是0，即下一种情况。

- timeout为0

无限期等待，直到有人来唤醒它。

让线程（即SystemServer的运行环境）进入等待所用的是wait()，那么唤醒它的就是notify/notifyAll。后者是在什么时候被执行的呢？

可以看看post出去的Runnable究竟做了些什么。摘录如下：

```
public void run() {
   holder[0] = new WindowManagerService(context, pm, dm
         uiHandler, haveInputMethods, showBootMsgs, onl
}
```

其实也就是新建了一个WindowManagerService对象，并没有我们想要的notify。大家可以想一想还有哪些地方比较可疑。

没错，就是BlockingRunnable。这个对象在执行run函数时同时会有一个特殊操作，如下：

```
public void run() {
   try {
       mTask.run();
   } finally {
       synchronized (this) {
          mDone = true;
          notifyAll();//通知所有正在等待它的人，“我运行成功了”…
       }
   }
}
```

其实WindowManagerService的作者绕了个大圈圈，就是为了表达图5-14所示的功能。

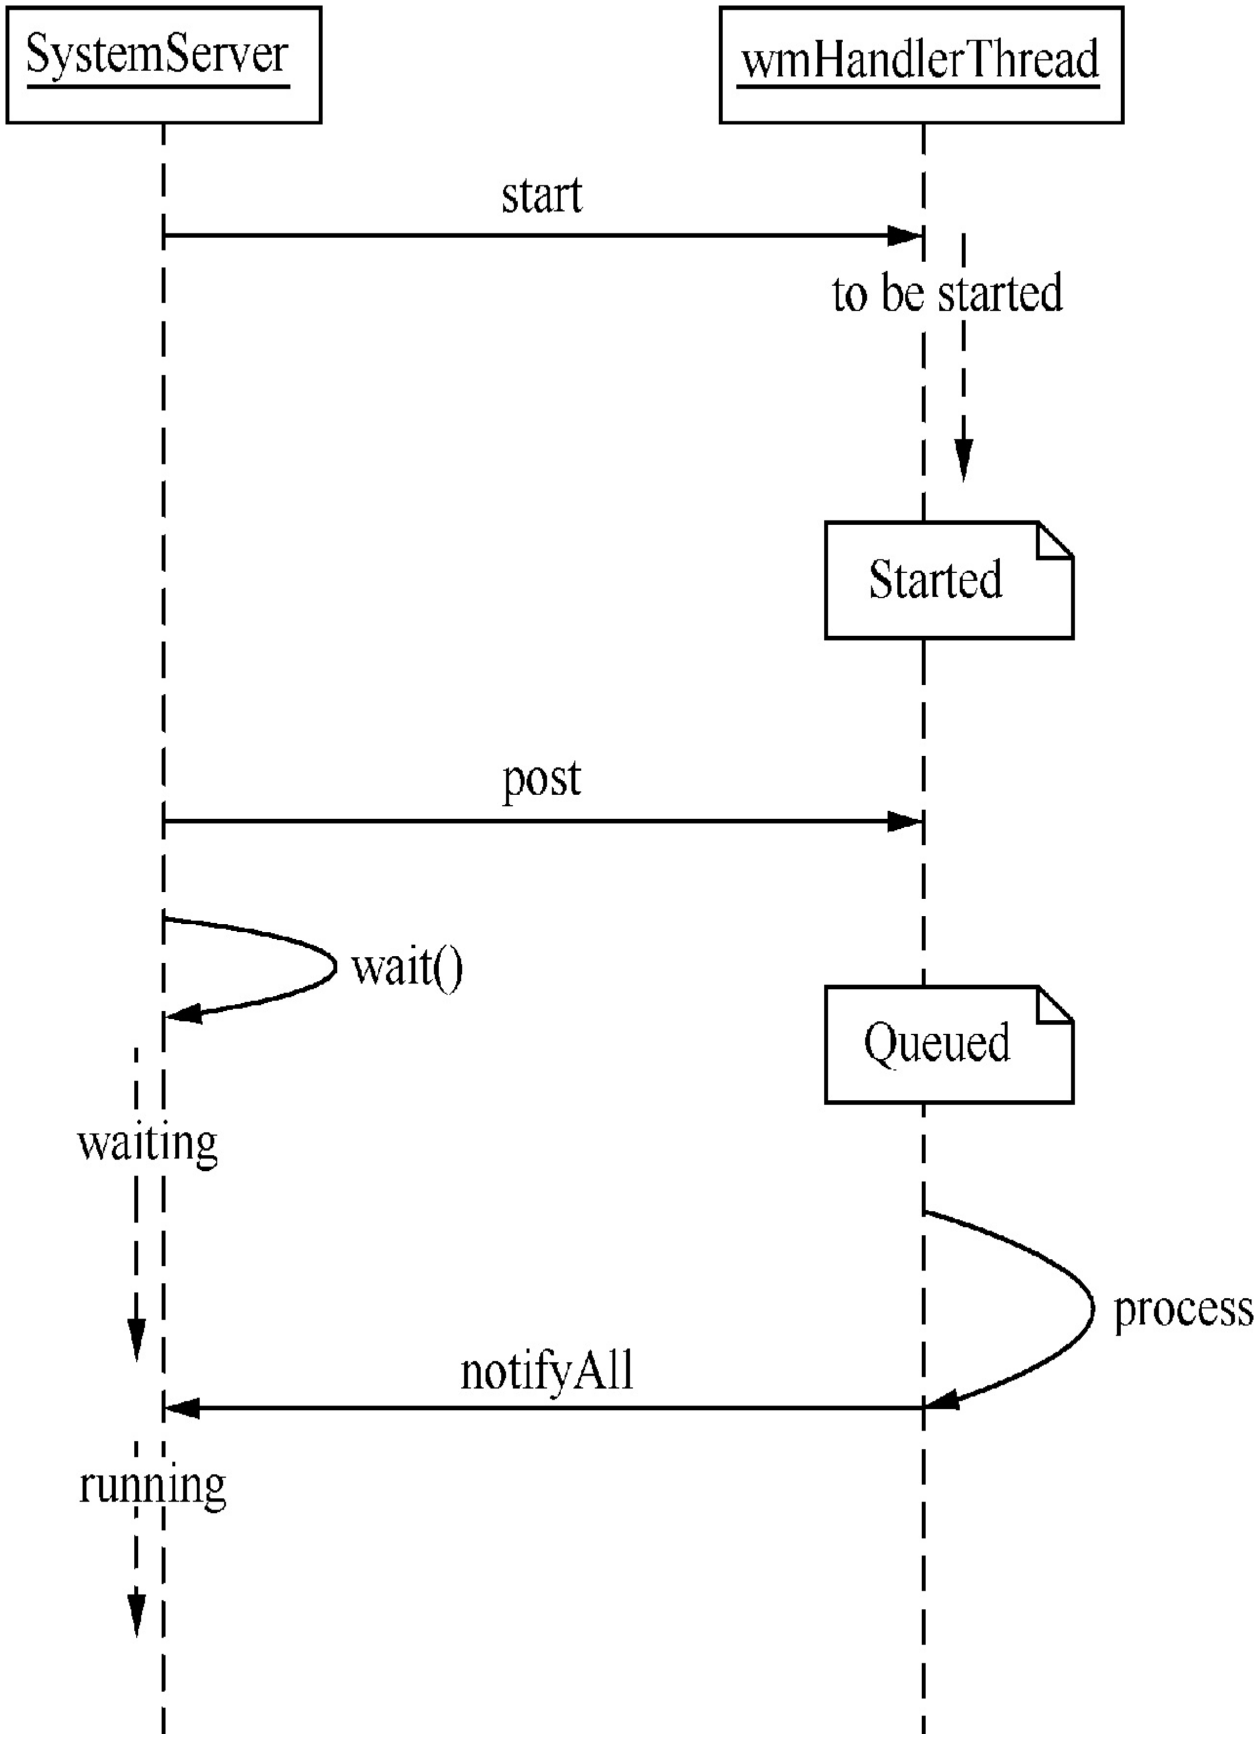
SystemServer
wmHandlerThread
start
to be started
Started
post
wait()
Queued
waiting
process
notifyAll
running

▲图5-14 wait与notify/notifyAll

当某个线程（比如SystemServer所在线程）调用一个Object（比如BlockingRunnable）的wait方法时，系统就要在这个Object中记录这个请求。因为调用者很可能不止一个，所以可使用列表（见图5-15的waiting list）的形式来逐一添加它们。当后期唤醒条件（也就是BlockingRunnable执行了run后）满足时，Object既可以使用notify来唤醒列表中的一个等待线程，也可以通过notifyAll来唤醒列表中的所有线程，如图5-15所示。

值得特别注意的是，调用者只有成为Object的monitor后，才能调用它的wait方法。而成为一个对象的monitor有以下3种途径。

- 执行这个object的synchronized方法。
- 执行一段synchronized代码，并且是基于这个object做的同步。
- 如果object是Class类，可以执行它的synchronized static方法。

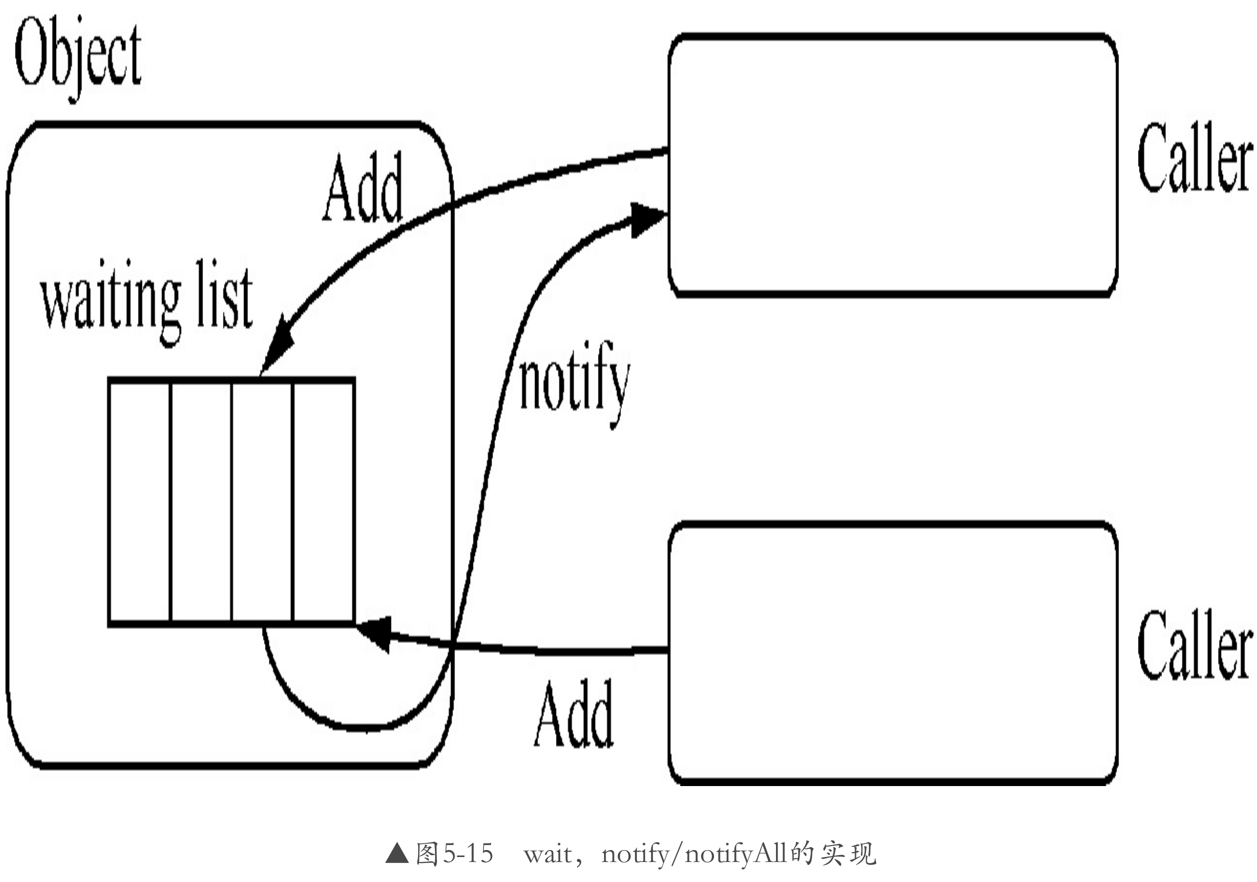

▲图5-15　wait，notify/notifyAll的实现

2．interrupt

如果说wait是一种“自愿”的行为，那么interrupt就是“被迫”的了。调用一个线程的interrupt的目的和这个单词的字面意思一样，就是“中断”它的执行过程。此时有以下3种可能性。

- 如果Thread正被blocked在某个object的wait上，或者join()，sleep()方法中，那么会被唤醒，中断状态会被清除并接收到InterruptedException。
- 如果Thread被blocked在InterruptibleChannel的I/O操作中，那么中断状态会被置位，并接收到ClosedByInterruptException，此时channel会被关闭。
- 如果Thread被blocked在Selector中，那么中断状态会被置位并且马上返回，不会收到任何exception。

3．join

join方法有如下几个原型：

```
public final void join ();
public final void join (long millis, int nanos);
public final void join (long millis);
```

比如：

```
Thread t1 = new Thread(new ThreadA());
Thread t2 = new Thread(new ThreadB());
t1.start();
t1.join();
t2.start();
```

它希望达到的目的就是只有当t1线程执行完成时，我们才接着执行后面的t2.start()。这样就保证了两个线程的顺序执行。而带有时间参数的join()则多了一个限制，即假如在规定时间内t1没有执行完成，那么我们也会继续执行后面的语句，以防止“无限等待”拖垮整个程序。

4．sleep

这个方法是工程项目中使用最广泛的，它和wait一样都是属于“自

愿”的行为。只不过wait是等待某个object，而sleep则是等待时间，一旦设置的时间到了就会被唤醒。原型如下：

```
public static void sleep (long millis, int nanos);
public static void sleep (long time);
```

这个方法比较简单，这里就不详细讲解了。

最后结合这两小节的内容给出Thread状态的迁移，具体如图5-16所示。

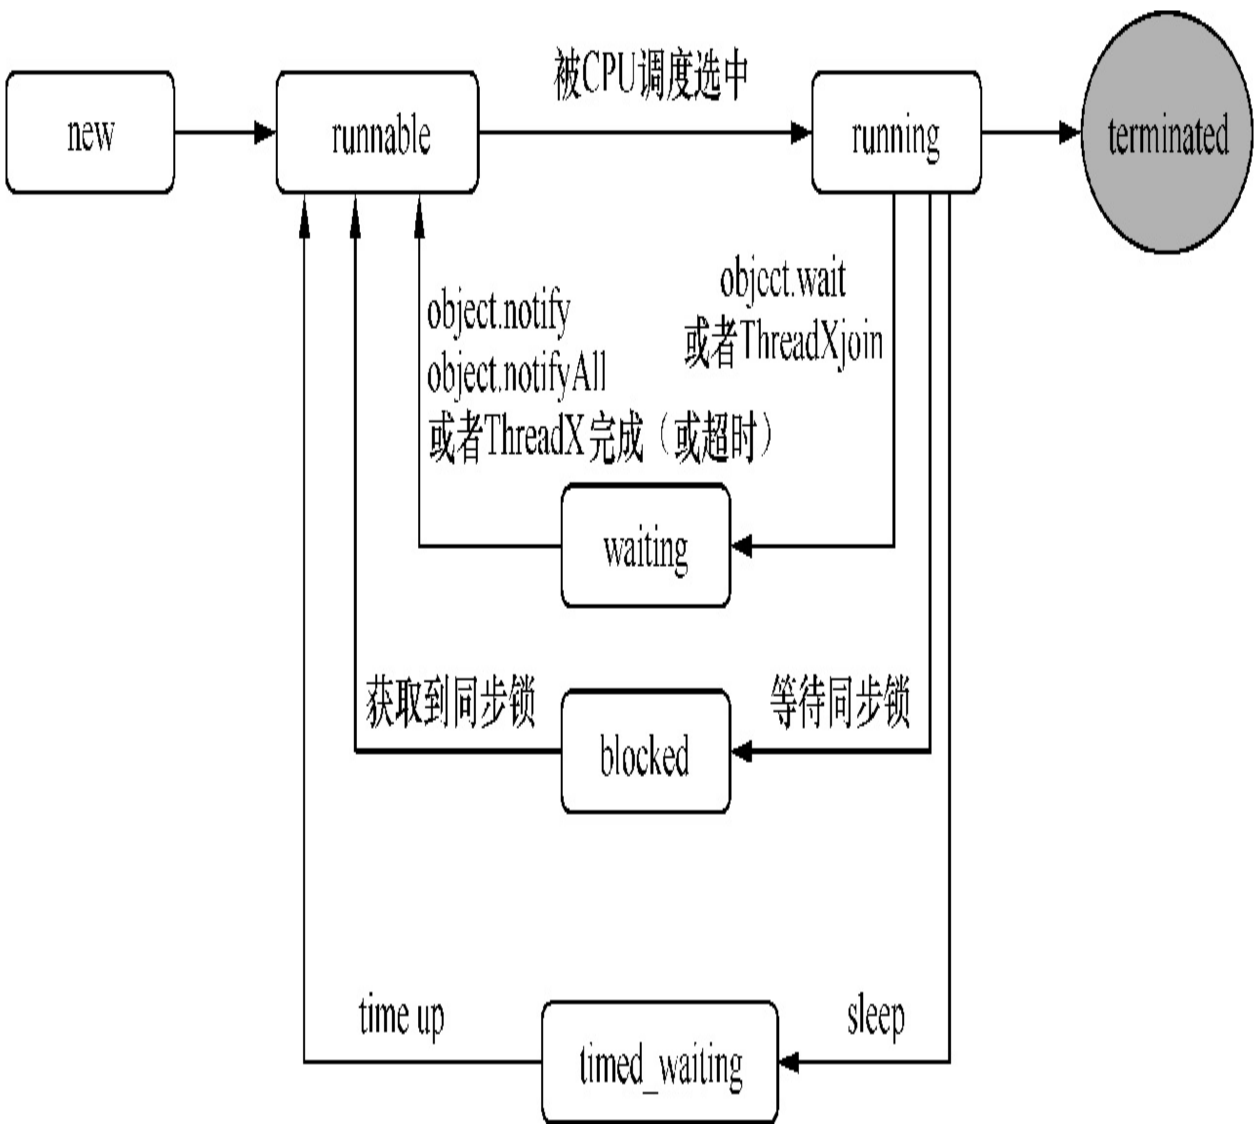

▲图5-16　Thread状态迁移图

5.4.3 Thread实例

为了加深大家对Thread的理解，这一小节讲解实际项目工程中的一个典型范例。

其目标是使用SeekBar（当用户的选择有变化后，会回调onProgressChanged函数）来控制系统的音效（比如调整高音部分增益，范围12～+12db）。要求UI界面的响应流畅（要求1），并且要能实时反映出音效的变化（要求2），另外系统必须稳定（要求3）。

假设有如下几个前提。

- 向系统发送音效调整的命令是一个费时的操作（前提1）。
- 频繁向系统发送调整命令将导致死机（前提2）。
- 用户的操作是随意没有规律的。有的用户很可能会迅速拉动SeekBar的滑杆，也可能慢慢拖动，或者快速来回拖动，这都是未知的。但我们必须保证UI界面不出现延滞现象（前提3）。

对于要求1，我们首先可以想到的是，将发送命令这一费时的操作放入一个独立的线程中执行。这样就不会影响主线程刷新UI，保证了界面的流畅。

而根据上述的前提描述，要求2和要求3是有矛盾的——如果我们需要实时听到音效的变化，则意味着SeekBar在变化过程中的数值应该不断地发送给系统，而不是等到用户松开手后才发送最终调整值。但如果按照这样的设计，那么当用户的操作非常迅速或者不停地来回拖动时，又会产生大量的请求命令——根据前提2，这将导致系统死机，从而违背了要求3。

另外，既然向系统发送命令是非常耗时的，那么频繁地发送命令也是没有意义的。举个例子，用户在1秒以内一下子从12拖到了+12的位置，从而产生了24个调整值（当然，SeekBar实际上可能不会产生这么多次onProgressChanged，这里假设会有24个），而发送每个调整值则需要500ms。换句话说，即便系统能稳定快速地处理调整请求，也需要等到用户松开手后的0.5*241=11秒后才能逐步听到音效的变化，这显然没有达到我们的设计目标。

所以解决的办法就是既要向系统不断地发送调整值，以保证用户能实时听到声音变化；而且又不能过于频繁，以保证系统稳定和UI界面的流畅。

那么，如何做到呢？

一种理论的办法就是计算用户在单位时间内产生的调整次数，然后进行适当取舍。缺点是明显的——程序很难界定什么样的情况是“频繁”，而且程序的逻辑会由此变得异常复杂，不利于维护和升级。

再来想想有没有其他简单的方法。

当启动一个新线程用于处理调整请求时，显然需要把这些请求先放入消息队列中再排队处理。根据前面的假设，如果用户在1秒内产生了24个调整值，那么队列中的数量将陆续增加，直到用户操作结束（因为500ms才能处理一个）。这些请求值实际上是有优先级的，即后产生的调整值更贴近于用户想得到的效果。根据这一思想，我们可以适当控制消息队列中的元素数量。比如：

- 当产生一个新的调整值时，先清空消息队列，然后才把请求入队；
- 当产生一个新的调整值时，先判断消息队列的数量，根据实际情况删除部分消息，然后才把请求入队。

另外，采用这种方式可以保证最后一个入队的请求总是可以被处理（没有后续的请求能清除它）。这也就意味着用户最终选择的音效值是可以体现出来的。

参考代码如下（BusinessThread）：

```
private Thread mBusinessThread = null;
private boolean mBusinessThreadStarted = false;
private BusinessThreadHandler mBusinessThreadHandler = null;
private void startBusinessThread()
{
     if (true == mBusinessThreadStarted)
          return;
     else
          mBusinessThreadStarted = true;
     mBusinessThread = new Thread(new Runnable()
     {
```

```
            @Override
            public void run()
            {
                 Looper.prepare();
                 mBusinessThreadHandler = new BusinessThreadHandler
                 Looper.loop();
            }
       });
       mBusinessThread.start();
}
```

BusinessThread重写了run方法，并使用Looper.prepare和Looper.loop来不断处理调整请求。这些请求是通过mBusinessThreadHandler发送到BusinessThread的消息队列中的。具体如下所示：

```
publicclass BusinessThreadHandler extendsHandler
{
       publicboolean sendMessage(int what, int arg1, int arg2)//重写
       {
            removeMessages(what); //清理消息队列中未处理的请求
            returnsuper.sendMessage(obtainMessage(what, arg1, arg2)
       }
       publicvoid handleMessage(Message msg)
       {
            switch(msg.what)
            {
            caseMSG_CODE:
                 //在这里执行耗时操作
                 break;
            default:
                 break;
            }

       }
};
```

在sendMessage方法中，首先清除了消息队列中还未被处理的请求（可以根据实际需求来调整这里的操作）。这样一方面降低了程序向系统发送请求的频率，加快了响应速度和UI界面的流畅性；另一方面也保证了BusinessThreadHandler下次取到的是优先级较高的调整请求值——最重要的是，用户能实时听到音效的变化。

这样我们就通过Thread+Handler+Looper的组合解决了工程项目中

的这个典型问题。

本例为了说明问题，简化了一些控制操作，读者可以根据需要补充完整。

5.5 Android应用程序如何利用CPU的多核处理能力

2012年的时候，Intel曾发表过非官方声明，称Android系统还没为CPU的多核能力做好充足的准备——多核所带来的“弊”甚至多于“利”。这种情况显然不能被Google所容忍，并在随后的版本中不断被优化和改善，使得Android系统不再为此而广受诟病。

那么，开发人员如何主动去利用CPU的多核能力，从而有效提高自身应用程序的性能呢？

答案就是针对Java-Based的并行编程技术。听起来有点复杂，但实际上相信大部分人都已经接触过了。第一种方式就是前面小节我们所提到的Java线程，它在Android系统中同样适用。使用上也和Java没有太多区别，我们只要继承Thread类或者实现Runnable接口就可以了。不过采用这类方法有一点比较麻烦的地方，就是和主线程的通信需要通过Message Queue——因为只有主线程才能处理UI相关的事务，包括UI界面更新。

另一种可选的并行编程方法是AsyncTask，它是Android开发的专门用于简化多线程实现的Helper类型的类。优点很明显，就是可以不需要通过繁琐的Looper、Handler等机制来与UI线程通信。Android官方对其的描述是：

“AsyncTask enables proper and easy use of the UI thread. This class allows to perform background operations and publish results on the UI thread without having to manipulate threads and/or handlers”。

AsyncTask在设计时的目标是针对比较短时间的后台操作，换句话说，如果你需要在后台长时间执行某些事务的话，我们建议你还是使用java.util.concurrent包所提供的Executor、ThreadPoolExecutor和FutureTask等其它API接口。

第三种比较常用的“工作线程”实现模型是IntentService。大家应该已经猜到了，它是四大组件之一的Service的子类，区别就在于IntentService可以帮助开发人员以相当简洁的语句（只需要实现onHandleIntent接口）来对Service进行后台处理，而无需理会其中各

种琐屑的中间过程。

总的来说，在Android系统中通过多线程编程模型来利用CPU的多核能力的途径还是比较多的。除上本小节例举的几个方式外，大家还可以到Android官网上查找学习更多类似的实现，并将它们应用到最匹配的需求场景中。

5.6 Android应用程序的典型启动流程

从上面小节的分析中，我们了解到Android系统中一个应用程序的主体是由ActivityThread构成的。不过这里面还涉及很多细节，如ActivityThread是由谁来创建的，又是在什么时间创建的呢？它和系统服务程序，如ActivityManagerService，WindowManagerService之间又有什么联系？了解这些知识有助于我们分析Android系统中应用程序框架的设计。

由于Android系统是基于Linux的，原则上说它的应用程序并不只是APK一种类型。换句话说，所有Linux支持的应用程序都可以通过一定方式运行在Android系统上（比如一些系统级应用程序就是以这种方式存在的，后面章节我们会逐步接触到）。为了叙述的统一，在没有特别说明的情况下，我们所指的应用程序都是APK类型的应用程序。它们通常由两种方式在系统中被启动。

- 在Launcher中点击相应的应用程序图标启动

这种启动方式大多是由用户发起的。默认情况下APK应用程序在Launcher主界面上会有一个图标，通过点击它可以启动这个应用程序指定的一个Activity。

- 通过startActivity启动

这种启动方式通常存在于源码内部。比如在Activity1中通过startActivity来启动Activity2。

这两种启动方式的流程基本上是一致的，最终都会调用ActivityManagerService的startActivity来完成。整个调用流程的描述如图5-17所示。

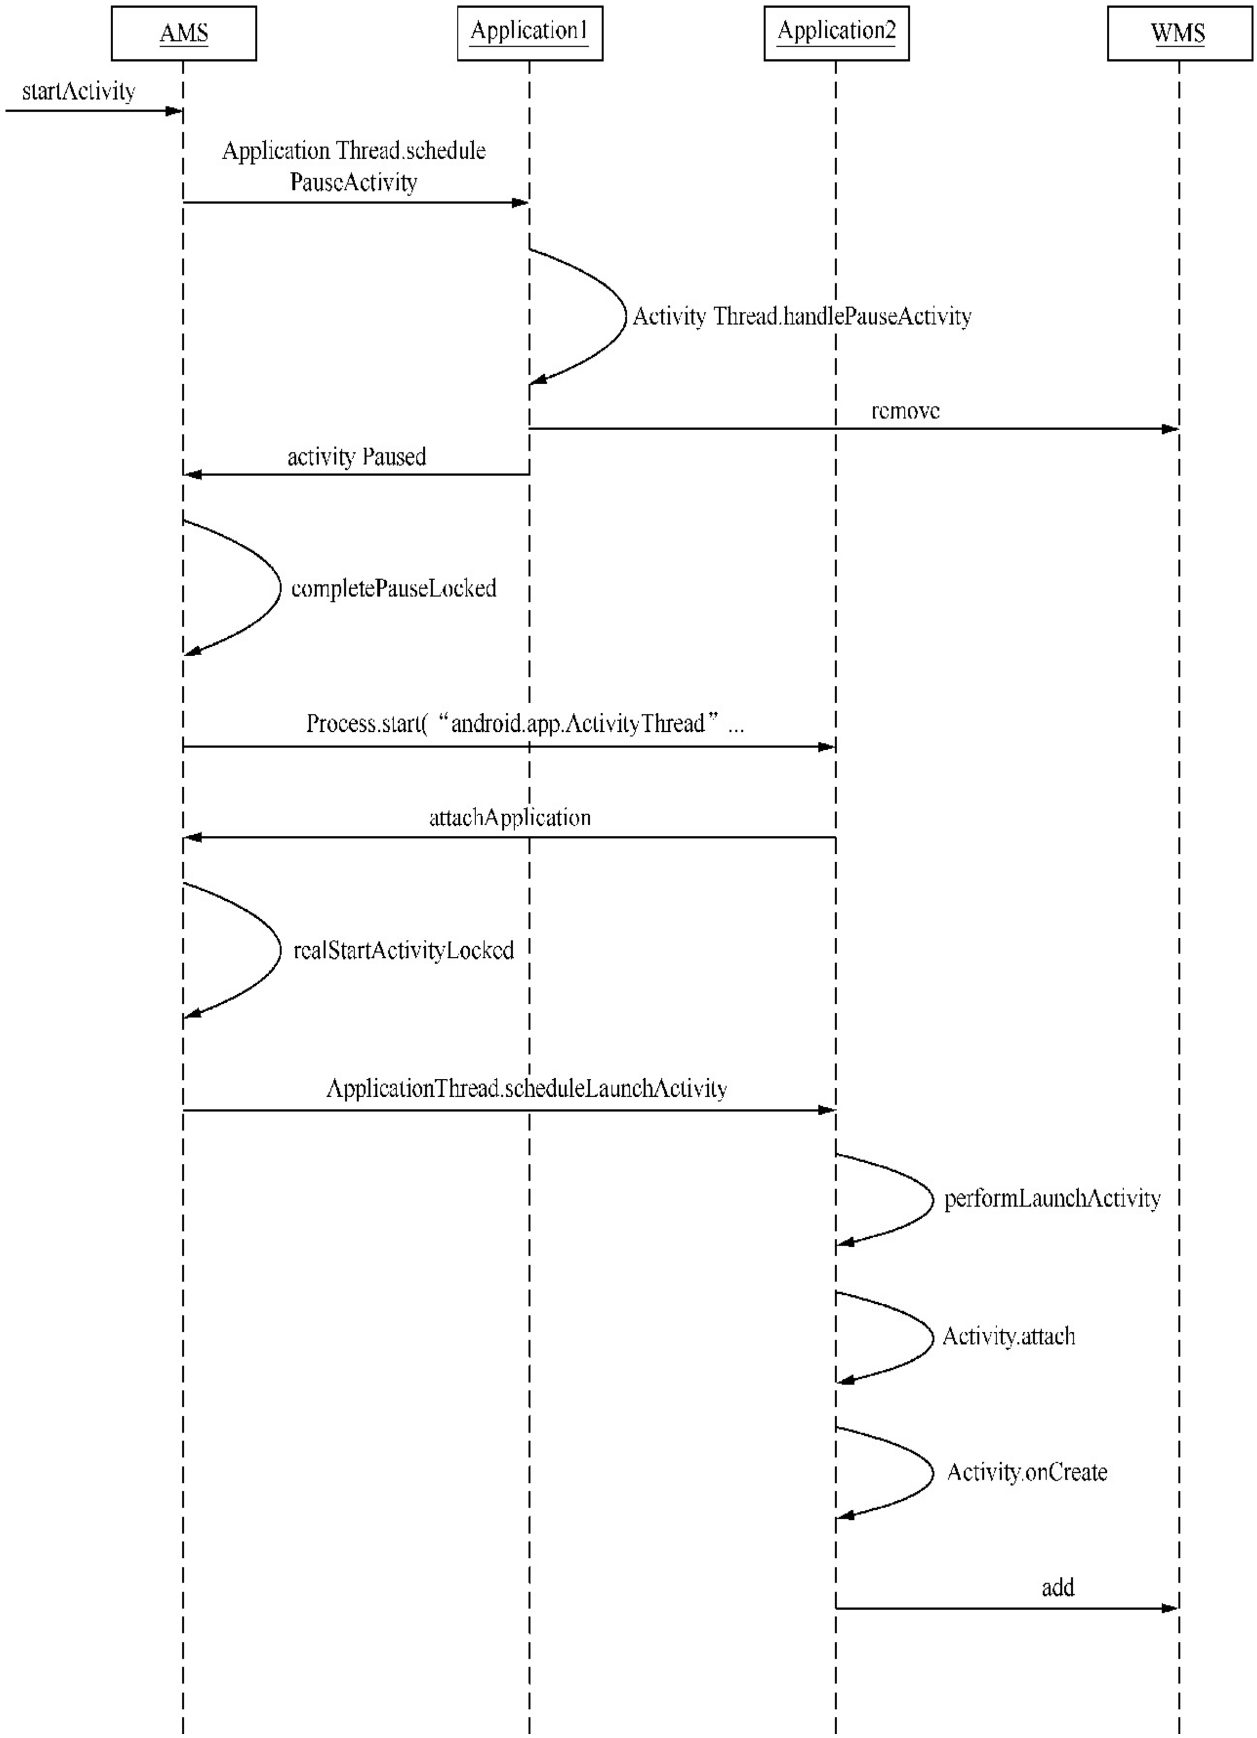
AMS
Application1
Application2
WMS
startActivity
Application Thread.schedule PauseActivity
Activity Thread.handlePauseActivity
remove
activity Paused
completePauseLocked
Process.start("android.app.ActivityThread" ...
attachApplication
realStartActivityLocked
ApplicationThread.scheduleLaunchActivity
performLaunchActivity
Activity.attach
Activity.onCreate
add

▲图5-17　应用程序的典型启动流程

无论以什么方式发起一个Activity的启动流程，最终都会调用到AMS的startActivity函数。在AMS真正启动一个Activity之前，需要经过众多烦琐的判断和准备工作——这些工作在AMS内部都由一系列以startActivity开头的函数来进行逐步处理。关于这部分内容，我们将在ActivityManagerService章节进行详细的分析，这里暂时跳过。

如果一切顺利，AMS才会最终尝试启动指定的Activity。如果读者写过APK应用程序，应该清楚Activity的生命周期中除了onCreate，onResume外，还有onPause，onStop等。其中的onPause就是在此时被调用的——因为Android系统规定，在新的Activity启动前，原先处于resumed状态的Activity会被pause。这种管理方式相比于Windows的多窗口系统简单很多，同时也完全可以满足移动设备的一般需求。将一个Activity置为pause主要是通过此Activity所属进程的ApplicationThread.schedulePauseActivity方法来完成的。ApplicationThread是应用程序进程提供给AMS的一个Binder通道，后面还会讲到。

当收到pause请求后，此进程的ActivityThread主线程将会做进一步处理。除了我们熟悉的调用Activity.onPause()等方法外，它还需要通知WindowManagerService这一变化——因为用户界面也需要发生改变。做完这些以后，进程通知AMS它的pause请求已经执行完成，从而使得AMS可以接着完成之前的startActivity操作。

假如即将启动的Activity所属的进程并不存在，那么AMS还需要先把它启动起来。这一步由Process.start实现，它的第一个入参是“android.app.ActivityThread”，也就是我们上一小节讨论的应用程序的主线程，然后调用它的main函数。

和前面一样，ActivityThread启动并做好相应初始化工作后，需要调用attachApplication来通知AMS，后者才能继续执行未完成的startActivity流程。具体而言，AMS通过ApplicationThread.scheduleLaunchActivity请求应用程序来启动一个指定的Activity。之后的一系列工作就要依靠应用进程自己来完成，如Activity创建Window，ViewRootImpl，遍历View Tree等。关于Activity中的详细显示过程，我们将在本书显示系统章节分两部分阐述——第一部分以View

和ViewRootImpl为核心；第二部分则以WindowManagerService为核心。

在进入后面章节的学习前，建议读者先熟悉本小节所述的startActivity的整个调用流程。实际上，这一看似简单的启动过程，基本涵盖了Android系统中的方方面面，如AMS、WMS、ActivityThread、Activity、ViewRoot、SurfaceFlinger、Window以及Binder通信等，因而可以作为我们深入分析系统的一条线索。

5.7 Android程序的内存管理与优化

相对于传统桌面型的应用程序，移动终端设备在内存、CPU和电池等关键资源上对应用程序提出了更严苛的要求。其中内存管理与优化的好坏，直接影响到程序的性能及用户体验，因而是所有开发人员不容忽视的核心环节。

5.7.1 Android系统对内存使用的限制

Android是一个支持多任务运行的系统，这意味着每个程序所占用的内存越小，理论上可以同时运行的进程数量就越多。随着硬件设备的不断升级换代，Android虚拟机系统允许单个进程所能使用的Heap Size的上限也在呈现上升趋势。具体来说，这个值是由特定的系统属性“dalvik.vm.heapsize”决定的。譬如Android 5.0版本中的堆大小是：

```
root@generic_x86:/ # getprop|grep dalvik.vm.heapsize
[dalvik.vm.heapsize]: [48m]
```

一旦进程申请的heap空间超过系统的阈值，就会引发OutOfMemory（OOM）的错误。不过发生这种情况通常只能说明个体情况的“违规”，而不是设备真地已经没有任何可用的内存空间了。

在Android系统中查看某个进程中的内存使用情况可以使用dumpsys命令，如图5-18是针对Calendar的一个范例。

```
root@generic_x86:/ # dumpsys meminfo 2008
Applications Memory Usage (kB):
Uptime: 661262 Realtime: 661262

** MEMINFO in pid 2008 [com.android.calendar] **
                   Pss  Private  Private  Swapped     Heap     Heap     Heap
                 Total    Dirty    Clean    Dirty     Size    Alloc     Free
                ------   ------   ------   ------   ------   ------   ------
  Native Heap     2487     2396        0        0     4466     4466     1677
  Dalvik Heap      493      440        0        0      801      448      353
 Dalvik Other      212      212        0        0
        Stack      120      120        0        0
    Other dev        4        0        4        0
     .so mmap      222       60        0        0
    .apk mmap      202        0        0        0
    .dex mmap      748        0      744        0
    code mmap      504        0       20        0
   image mmap      857      464        0        0
   Other mmap        4        4        0        0
      Unknown       45       44        0        0
        TOTAL     5898     3740      768        0     5267     4914     2030
```

▲图5-18　范例

可以看到Heap区域分为两类，即Native和Dalvik。前者是指本地代码的情况，而Dalvik Heap特指虚拟机中的堆分配。

值得一提的是，Android系统允许开发人员在AndroidManifest.xml的<application>中将android:largeHeap赋值为true，以便获得更大的Heap Size。Large Heap Size的具体值可以通过getLargeMemoryClass()来取得。不过，这个方法只限于一些确实需要大内存空间的程序（如图像处理类程序），切忌在出现OOM时为了偷懒而直接使用它，这样所带来的最终后果通常是得不偿失的。

PSS是Proportional Set Size的缩写。简单来讲，PSS=进程独占的内存页+按比例分配与其他进程共享的内存页。举个例子来说，如果有2个内存页被2个进程共享，那么它们的PSS数量值各增加1。

Private RAM表示被你进程独占的那部分内存空间，所以，在程序销毁后会被系统回收。它又可以分为两类，其中Private Dirty RAM指的是必须常驻内存的那些页面；相反的，Private Clean RAM则是可能被paged out的那些页面（如果长时间没用）。

其他各种“mmap”内存（如.so、.dex、.oat）特指映射这些对象

时所消耗的内存空间。当然，实际的值很可能比我们在meminfo中看到的要大。

有了这些基础后，我们在下一小节就可以进一步分析如何做内存监测和内存问题的定位了。

5.7.2　Android中的内存泄露与内存监测

Android提供了多种工具来辅助开发人员定位与解决内存相关问题，例如Logcat、Memory Monitor、Heap Viewer等。

（1）Logcat

根据虚拟机类型的不同分为两种情况，即Dalvik和ART。

其中Davlik下与GC相关的logcat格式是：

```
D/dalvikvm: <GC_Reason> <Amount_freed>, <Heap_stats>, <External_m
```

下面是一个范例：

```
D/dalvikvm( 9050): GC_CONCURRENT freed 2049K, 65% free 3571K/9991
5261K, paused 2ms+2ms
```

GC Reason表示发生垃圾回收的原因，可选项比较多，如表5-2所示。

表5-2　GC Reason及释义

GC Reason	Description
GC_CONCURRENT	当堆空间超过阈值时（换句话说，内存分配已经成功），产生的并行垃圾回收事件
GC_FOR_MALLOC	当程序试图去分配堆无法满足的空间大小时，系统需要暂停你的程序

	来回收更多内存
GC_HPROF_DUMP_HEAP	处理HPROF请求时产生的GC
GC_EXPLICIT	主动请求的GC，比如可以调用gc()函数来达到这一效果
GC_EXTERNAL_ALLOC	只适用于API等级10及以下的版本

<Amount_freed>表示本次GC释放的内存数量。

<Heap_stats>表示剩余堆大小占堆空间总大小的百分比。

<External_memory_stats>只适用于API等级10及以下的版本。

<Pause_time>表示GC导致的程序暂停时间。Concurrent类型下的暂停时间包含两部分：开始时和临近结束时。在我们这个范例中具体值是“paused 2ms+2ms”。

ART虚拟机和Dalvik有不小的差异，它只会在我们主动请求GC的情况下才会打印出logcat（或者GC的暂停时间或者总操作时间超过上限）。关于ART下的GC选项，请大家参考官方文档说明。

（2）Memory Monitor

Memory Monitor可以在Android Studio中启动，用于跟踪程序当前已经分配的和剩余的内存空间大小。如下范例如图5-19所示。

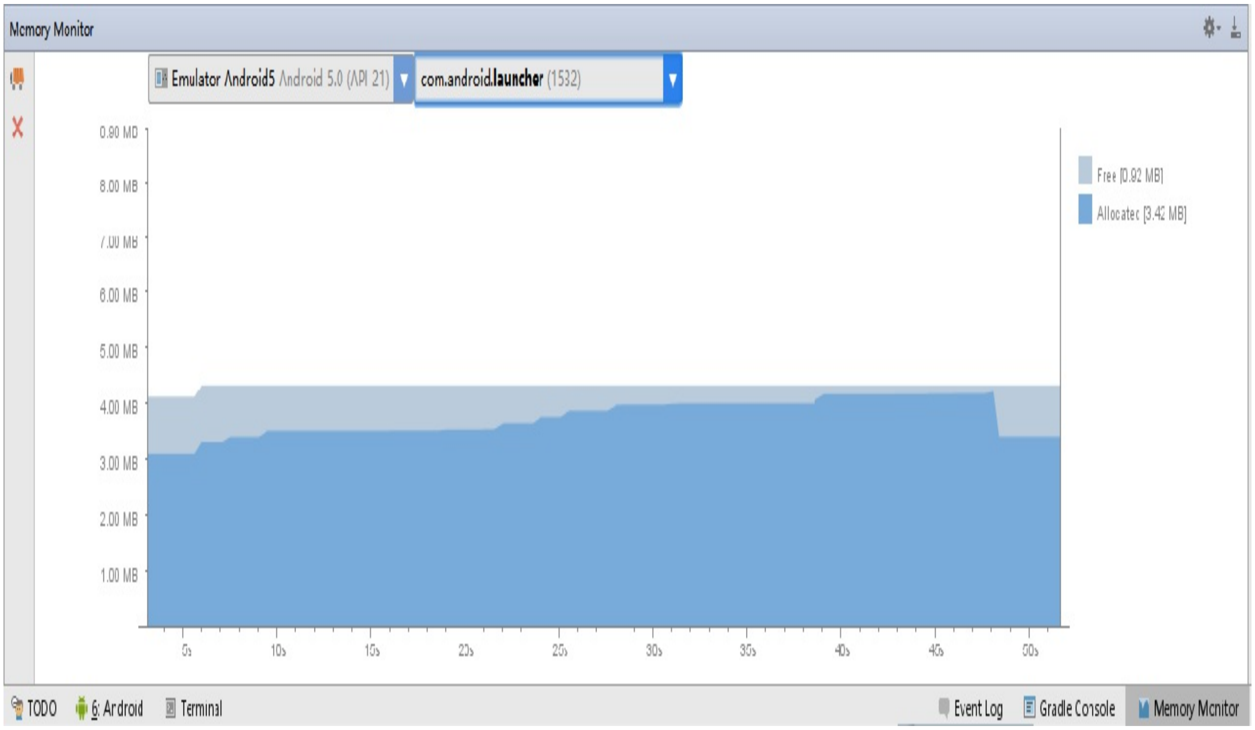

▲图5-19　内存空间大小

深色的表示已经分配的内存，浅色的表示空闲内存数。左侧的 按钮可以手工触发一次GC操作。此时Logcat中会输出垃圾回收的情况，例如：

1532-1539/com.android.launcher I/art：Explicit concurrent mark sweep GC freed 146(4KB) AllocSpace objects, 0(0B) LOS objects, 24% free, 4MB/6MB, paused 1.629ms total 15.895ms。

Memory Monitor可以帮助用户快速定位垃圾回收是否会引起应用程序响应缓慢，或者程序宕机是否与内存不足有关等问题。不过，更多的时候我们需要把它和其他内存工具结合使用才能发挥更大的作用。

（3）Heap Viewer

Heap Viewer可以从IDE或者Android的Android Device Monitor中启动，界面如图5-20所示。

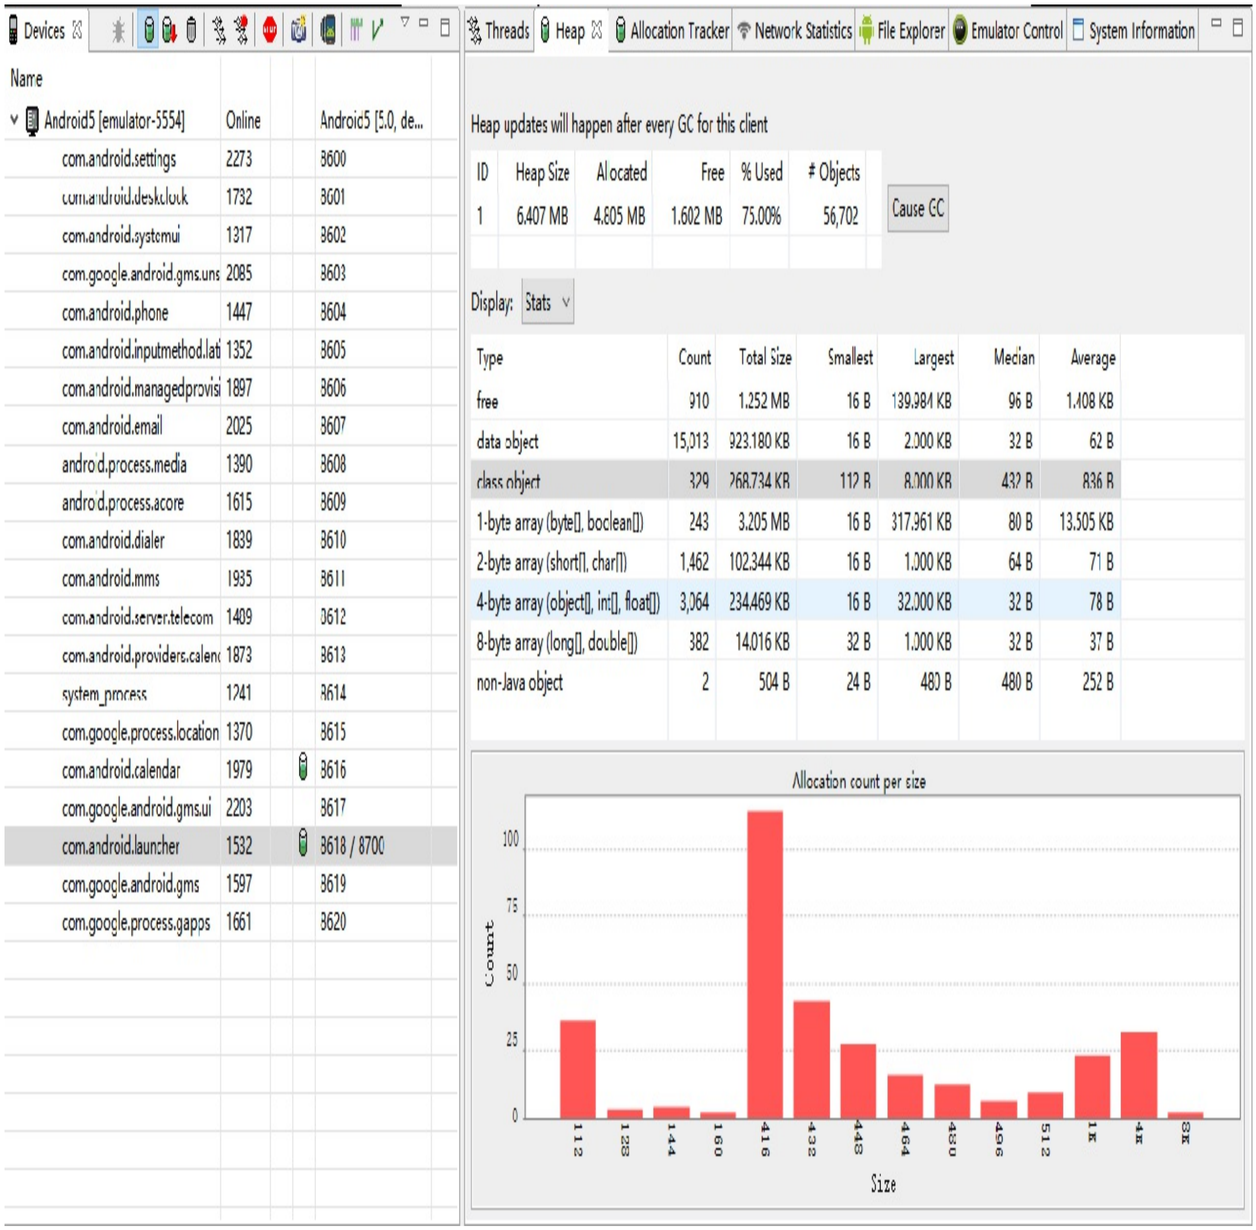

▲图5-20　Heap Viewer界面图

在图5-20所示的例子中，我们为com.android.launcher抓取了当前的Heap Status。Heap Viewer会特别提示开发人员：“Heap updates will happen after every GC for this client”。右侧的上半部分展示的是最新的Heap Size、Allocated Size、Free Size等信息；中间部分是对各种类型的对象进行空间占用分析的结果。比如在这个场景下class object共有329个，占用268734KB大小；下半部分则会对这些对象进行图形化分布，直观显示出各种size下的对象的具体数量。

（4）Allocation Tracker

开发人员使用Android提供的这些内存工具来定位问题的典型流程是：我们首先使用Memory Monitor来观察程序是否会经常性地发生GC事件（问题是否存在）——答案如果是肯定的话，再进一步利用Heap Viewer来甄别出可疑的对象类型（导致问题的可疑对象是什么），最后再借助于Allocation Tracker来确定发生问题的代码在哪个位置（问题是如何产生的）。

Allocation Tracker也支持从IDE或者Android Device Monitor中启动。以后者为例，它的整体界面如图5-21所示。

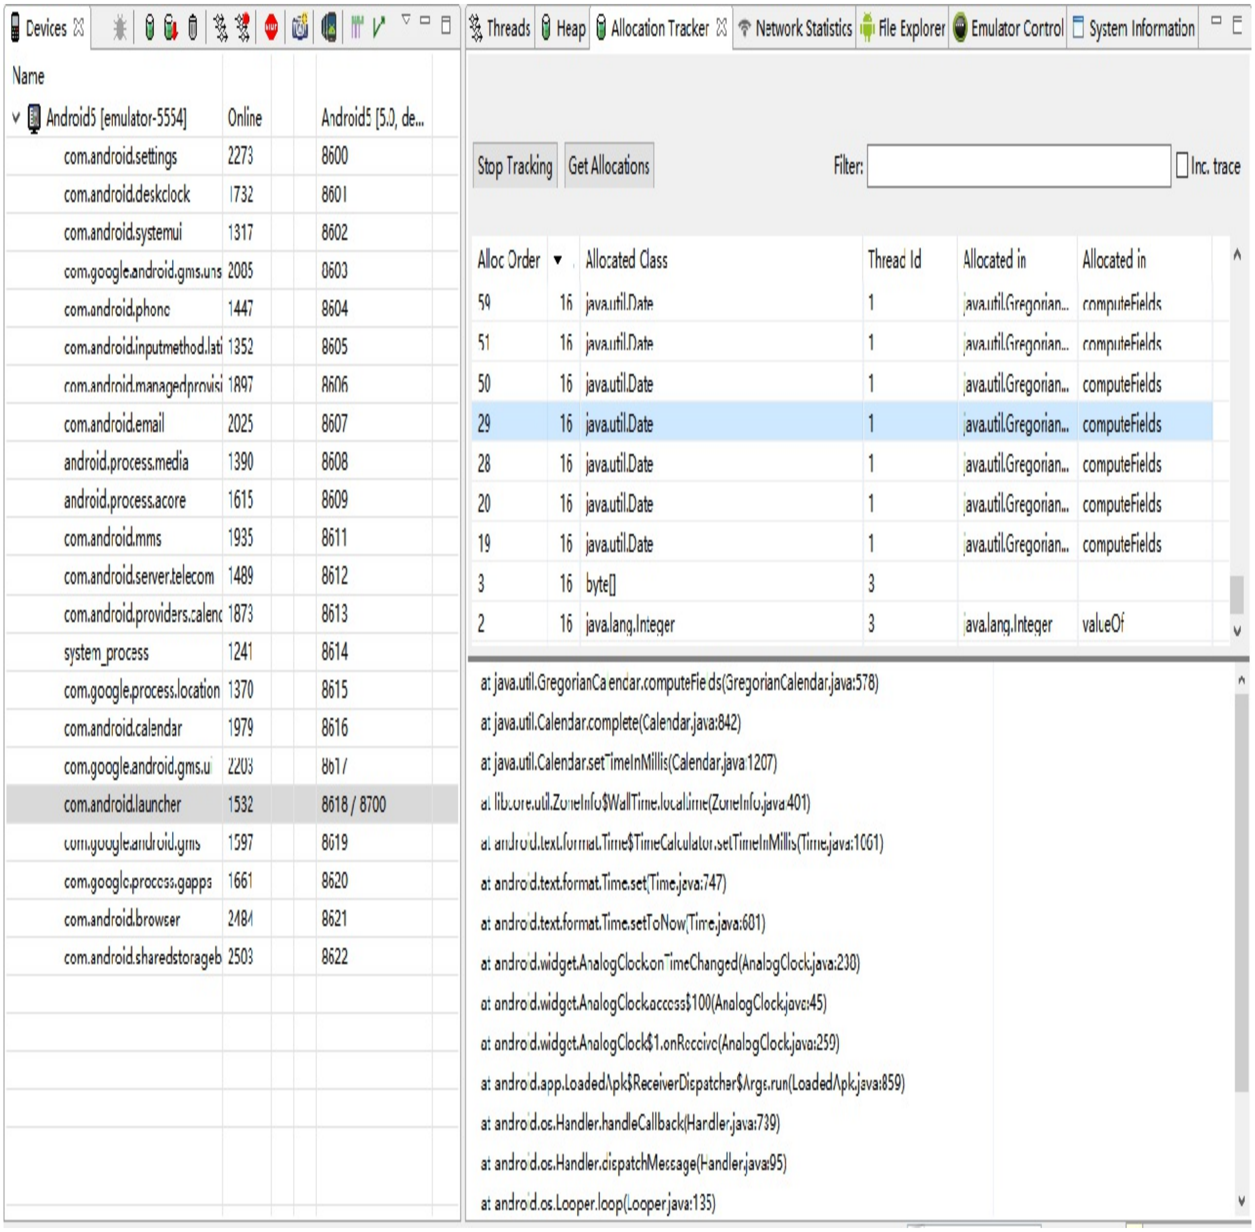

▲图5-21　Allocation Tracker界面图

Allocation Tracker可以获取各个对象的分配情况，包括它们的时间顺序、线程号，以及对象创建时的调用堆栈等完整信息。有了这些数据，我们就可以针对可疑对象“刨根究底”地分析出导致问题的源头在哪里了，从而采取有效的措施彻底解决这些问题。

（5）Memory Analyzer Tool

MAT（Memory Analyzer Tool）是由Eclipse社区贡献的一个非常著

名的内存分析工具，也是Java开发人员常用的内存泄露和内存优化的诊断利器。MAT支持HPROF文件格式，我们可以通过多种方式采集到它所需的数据。譬如DDMS就提供了Dump HPROF文件的功能，如图5-22所示。

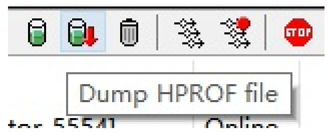

▲图5-22 文件的功能

值得一提的是，MAT是通用的Java Heap Analyzer，意味着它的应用范围绝不仅限于Android系统。如果大家有其他平台上的Java内存问题，同样可以利用这个工具进行分析。从DDMS中导出的HPROF需要通过转换才能变成标准的J2SE HPROF文件。Android SDK在platform-tools目录下提供了现成的hprof-conv工具来完成这个工作。

MAT的功能比较全面，我们下面只介绍开发者最关心的核心功能，如图5-23所示。

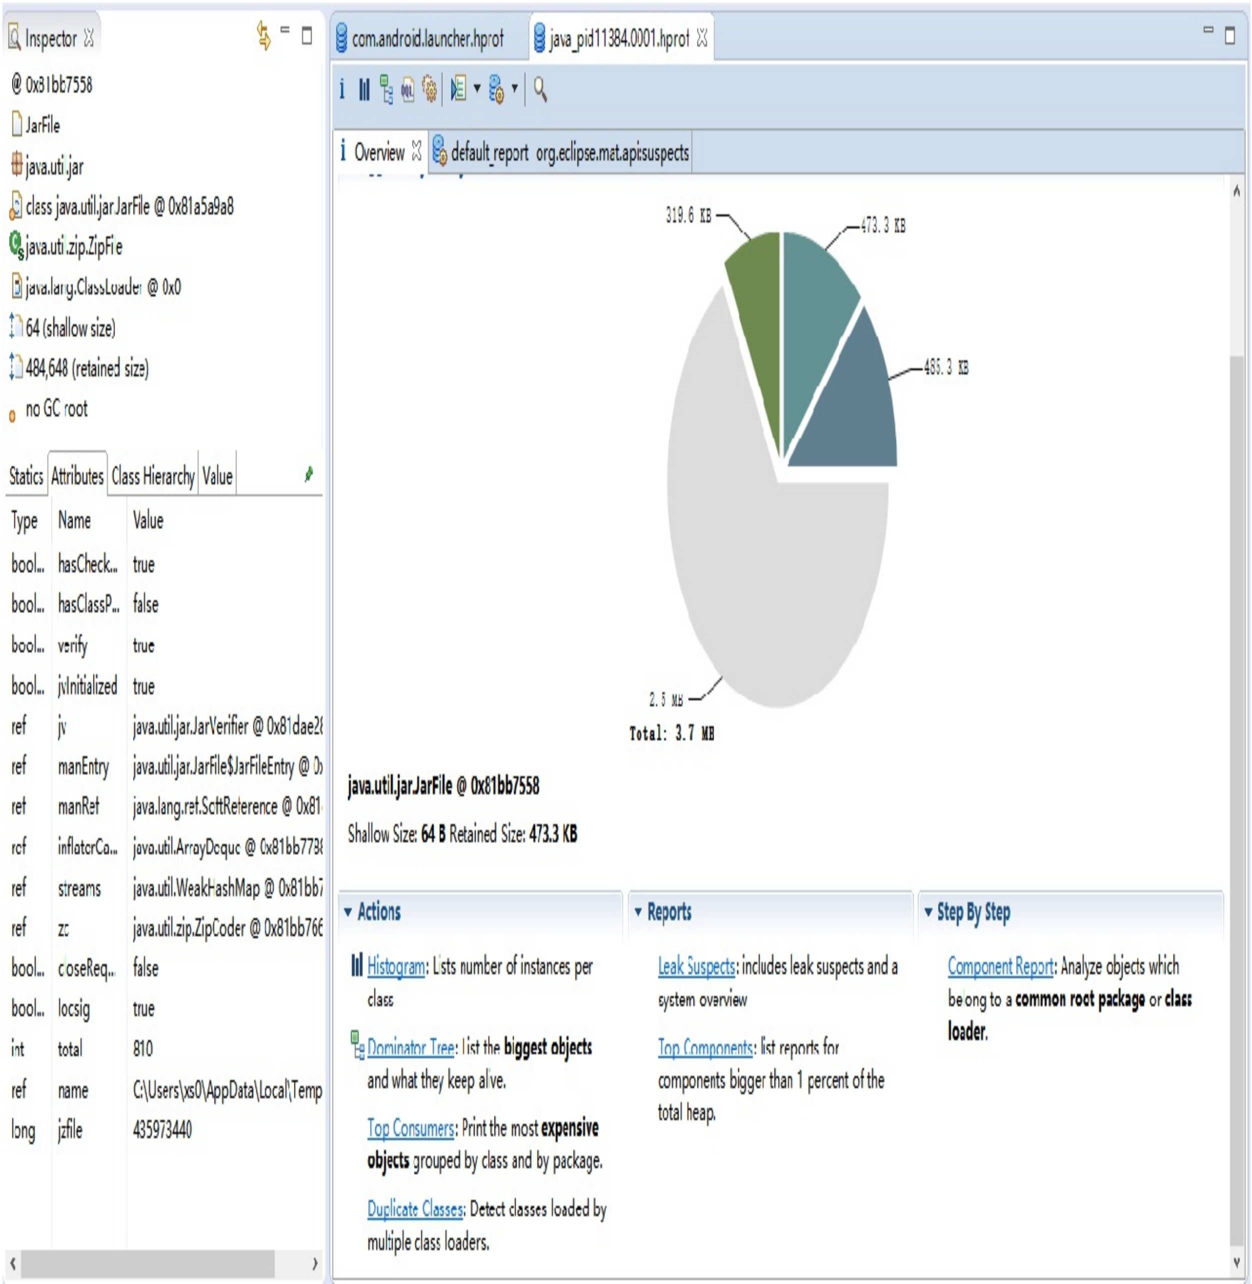

▲图5-23　MAT的功能

Overview页中包含了堆空间中的各种对象的统计信息。其中饼状图表示的是排名前几位的大文件对象。Histogram View是一个包含所有class的列表，以及每个class有多少个对象实例。某些特定类型的class（譬如Android应用程序中的Activity）通常只有一个实例，因而，如果在列表中发现这些对象的数量和预期不符，那么很可能是出现了问题，如图5-24所示。

Dominator tree从不同角度为开发者审视内存分配提供了便利，如图5-25所示。

Objects列表示对应的类的数量。Shallow Heap代表类对象本身所占用的内存空间，与之相对应的是Retained Heap——这个值是指对象本身，以及它引用的其他对象（如果一个对象被引用，那么它很可能无法被GC回收）所占的空间之和。

Memory Analyzer Tool同时提供了各类分析报告，其中对开发人员最有价值的可能是Memory Leak Report。一个范例报告如图5-26所示。

报告会先以饼状图的形式直观给出最有可能发生内存泄露的几个对象，紧随其后的是针对这些对象的逐一分析，如图5-27所示。

i Overview | Histogram

Class Name	Objects	Shallow Heap	Retained Heap
<Regex>	<Numeric>	<Numeric>	<Numeric>
char[]	16,404	1,747,208	>= 1,747,208
byte[]	911	558,128	>= 558,128
java.lang.String	15,925	382,200	>= 1,833,504
java.util.HashMap$Node	5,214	166,848	>= 984,616
int[]	846	95,832	>= 95,832
java.util.HashMap$Node[]	1,879	93,480	>= 1,038,784
java.util.HashMap	1,887	90,576	>= 1,028,784
java.util.Hashtable$Entry	2,222	71,104	>= 517,248
java.util.LinkedHashMap$Entry	1,437	57,480	>= 226,224
java.util.concurrent.ConcurrentHashMap$Node	1,773	56,736	>= 152,824
java.util.jar.Attributes$Name	1,812	43,488	>= 45,272
java.lang.Object[]	721	37,960	>= 442,632
java.lang.Class	2,069	35,976	>= 1,564,384
java.util.TreeMap$Entry	892	35,680	>= 224,952
java.lang.String[]	620	28,768	>= 152,216
com.sun.org.apache.xerces.internal.impl.dv.xs.XSSimpleTypeDecl	139	27,800	>= 60,192
java.util.jar.Attributes	1,717	27,472	>= 451,208

▲图5-24　Histogram View

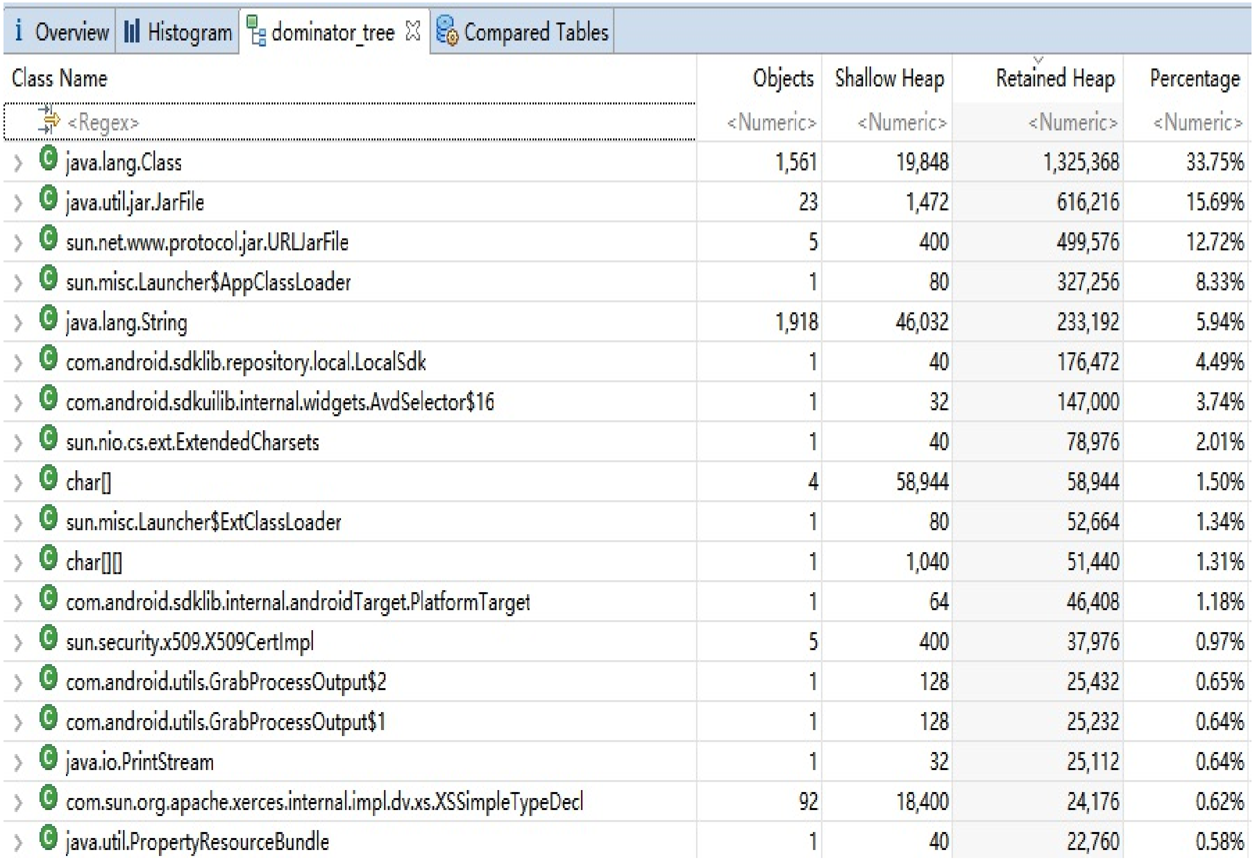

Class Name	Objects	Shallow Heap	Retained Heap	Percentage
<Regex>	<Numeric>	<Numeric>	<Numeric>	<Numeric>
java.lang.Class	1,561	19,848	1,325,368	33.75%
java.util.jar.JarFile	23	1,472	616,216	15.69%
sun.net.www.protocol.jar.URLJarFile	5	400	499,576	12.72%
sun.misc.Launcher$AppClassLoader	1	80	327,256	8.33%
java.lang.String	1,918	46,032	233,192	5.94%
com.android.sdklib.repository.local.LocalSdk	1	40	176,472	4.49%
com.android.sdkuilib.internal.widgets.AvdSelector$16	1	32	147,000	3.74%
sun.nio.cs.ext.ExtendedCharsets	1	40	78,976	2.01%
char[]	4	58,944	58,944	1.50%
sun.misc.Launcher$ExtClassLoader	1	80	52,664	1.34%
char[][]	1	1,040	51,440	1.31%
com.android.sdklib.internal.androidTarget.PlatformTarget	1	64	46,408	1.18%
sun.security.x509.X509CertImpl	5	400	37,976	0.97%
com.android.utils.GrabProcessOutput$2	1	128	25,432	0.65%
com.android.utils.GrabProcessOutput$1	1	128	25,232	0.64%
java.io.PrintStream	1	32	25,112	0.64%
com.sun.org.apache.xerces.internal.impl.dv.xs.XSSimpleTypeDecl	92	18,400	24,176	0.62%
java.util.PropertyResourceBundle	1	40	22,760	0.58%

▲图5-25 内存分配

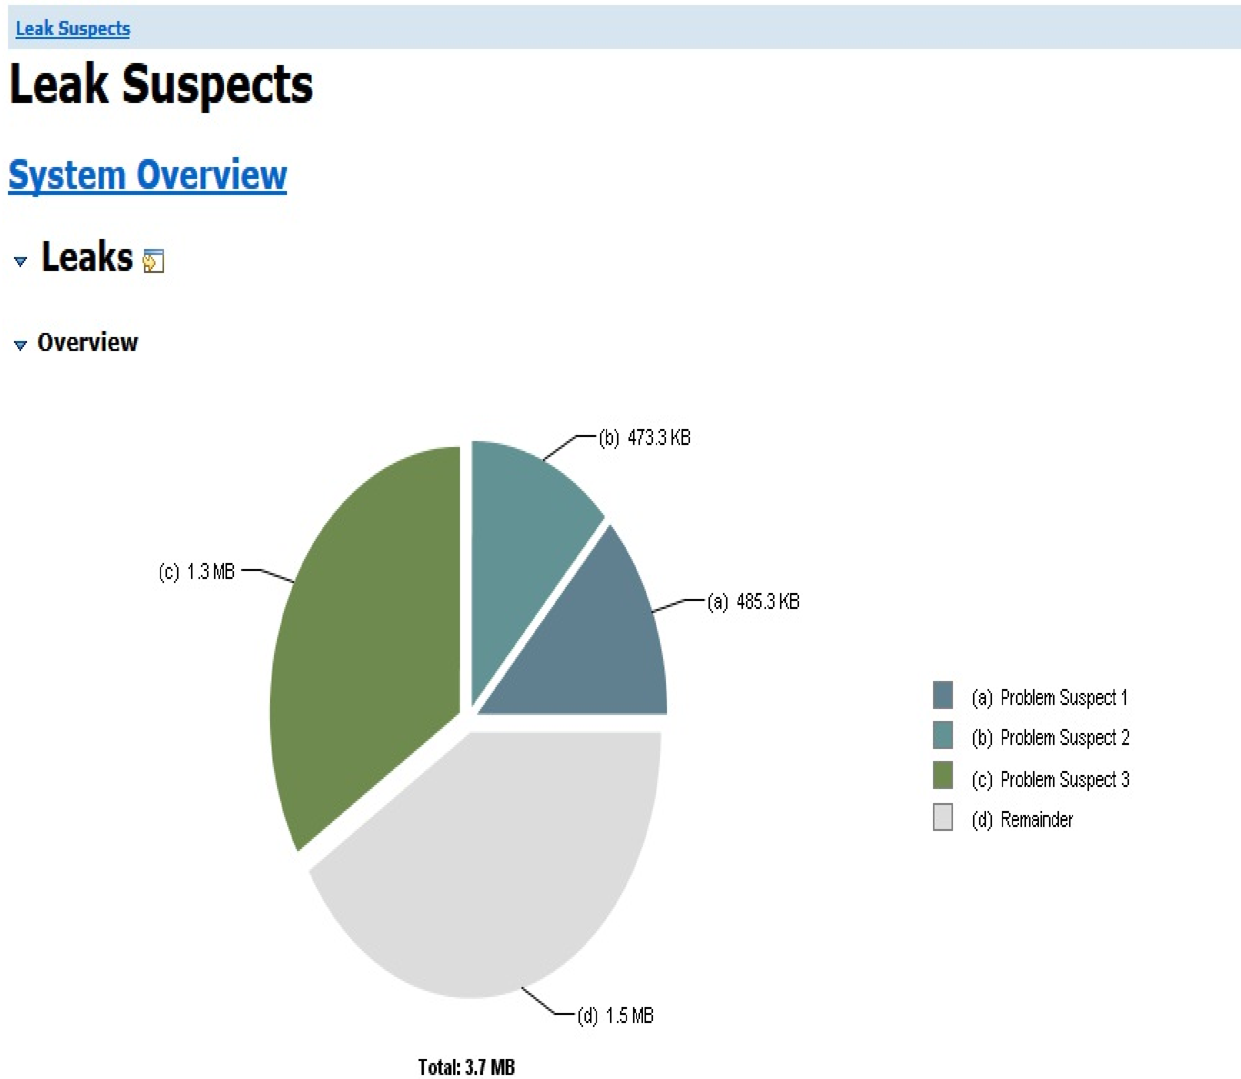

Leak Suspects
Leak Suspects
System Overview
Leaks
Overview
(b) 473.3 KB
(c) 1.3 MB
(a) 485.3 KB
(d) 1.5 MB
Total: 3.7 MB
(a) Problem Suspect 1
(b) Problem Suspect 2
(c) Problem Suspect 3
(d) Remainder

▲图5-26　范例报告

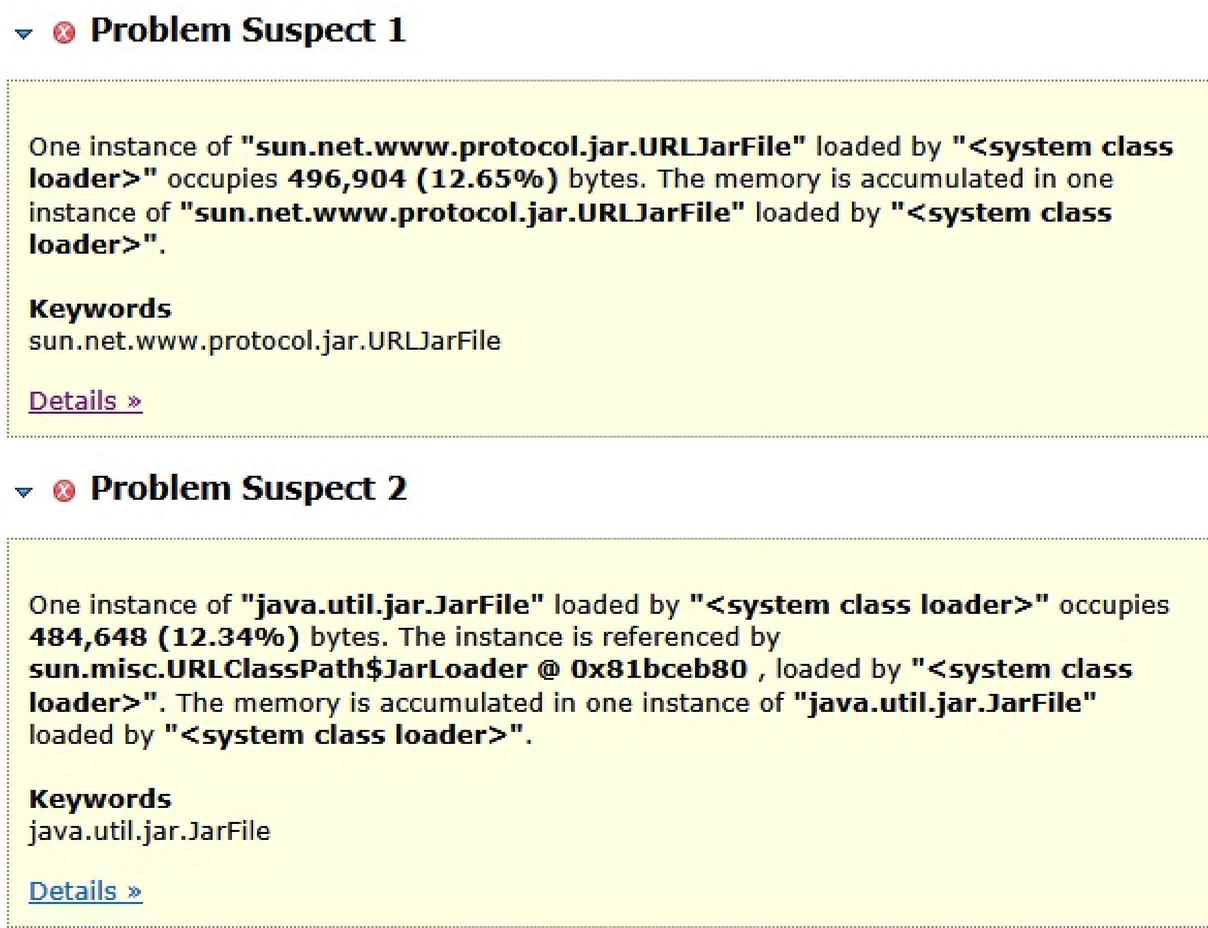

▲图5-27　对象的分析

单击图5-27中的“Details”后还会有与可疑对象相关的更多详细信息。总的来说，Memory Leak与程序业务逻辑有一定关系，并没有“放之四海皆准”的评价标准。但是MAT提供的信息可以让开发人员从“浩瀚”的代码中更快速地筛选出嫌疑对象，以此为基础来最终确定和解决问题。这也是MAT在Java程序开发中广受欢迎的一个重要原因。由于篇幅有限，关于MAT更多强大的功能，希望大家可以自行查阅相关资料来了解。

第6章

进程间通信——Binder

我们知道，同一个程序中的两个函数之间能直接调用的根本原因是处于相同的内存空间中。

比如有以下两个函数A和B：

```
/*Simple.c*/
void A()
{ B(); }

void B()
{ }
```

因为是在一个内存空间中，虚拟地址的映射规则完全一致（还记得我们在计算机基础章节中讨论过的虚拟内存吗），所以函数A和B之间的调用关系很简单，如图6-1所示。

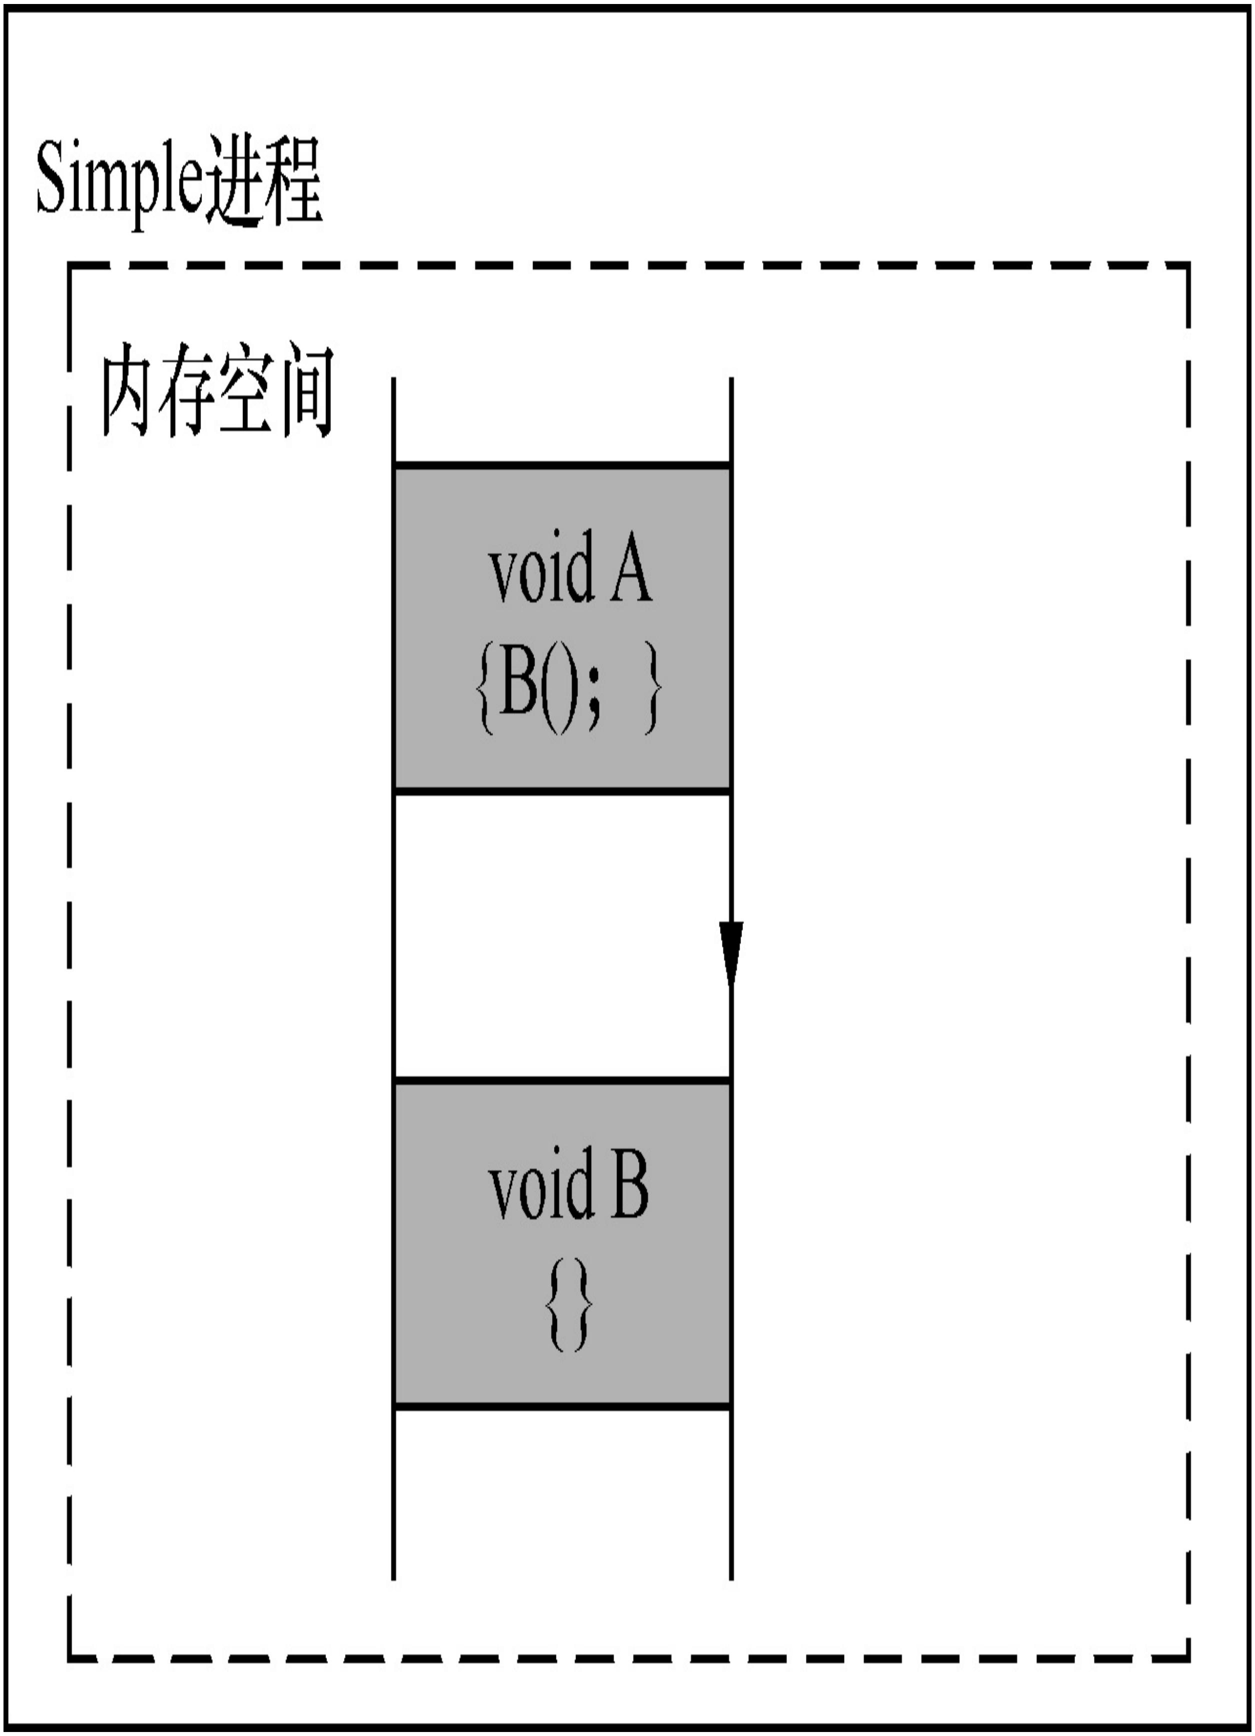
Simple进程
内存空间
void A
{B(); }
void B
{}

▲图6-1　同一进程空间中的函数调用

反之，两个不同的进程，如某Application1和ActivityManagerService（所在的进程），它们是没有办法直接通过内存地址来访问到对方内部的函数或者变量的，如图6-2所示。

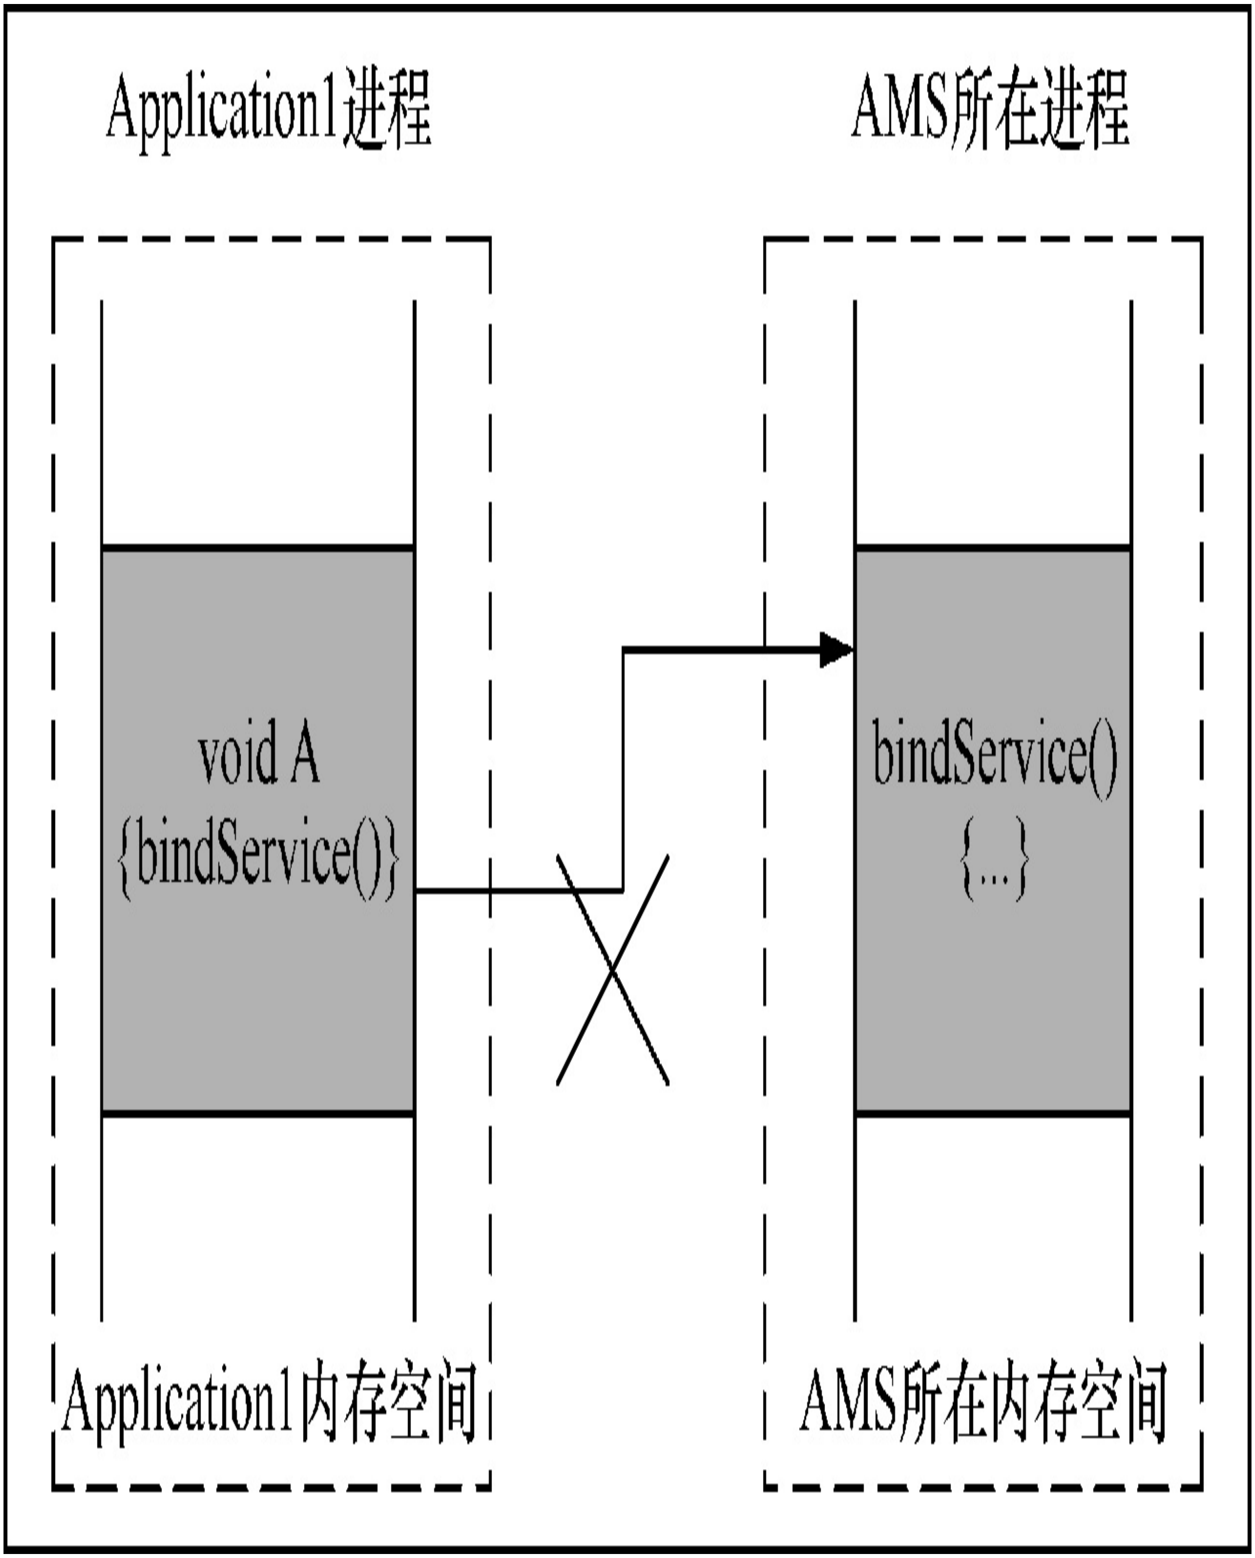

▲图6-2　跨进程时无法直接访问到对方的内存空间

既然无法“直接”访问到对方进程的内存空间，那有没有“间

接”的方法呢？简而言之，这就是Binder所要做的工作，如图6-3所示。

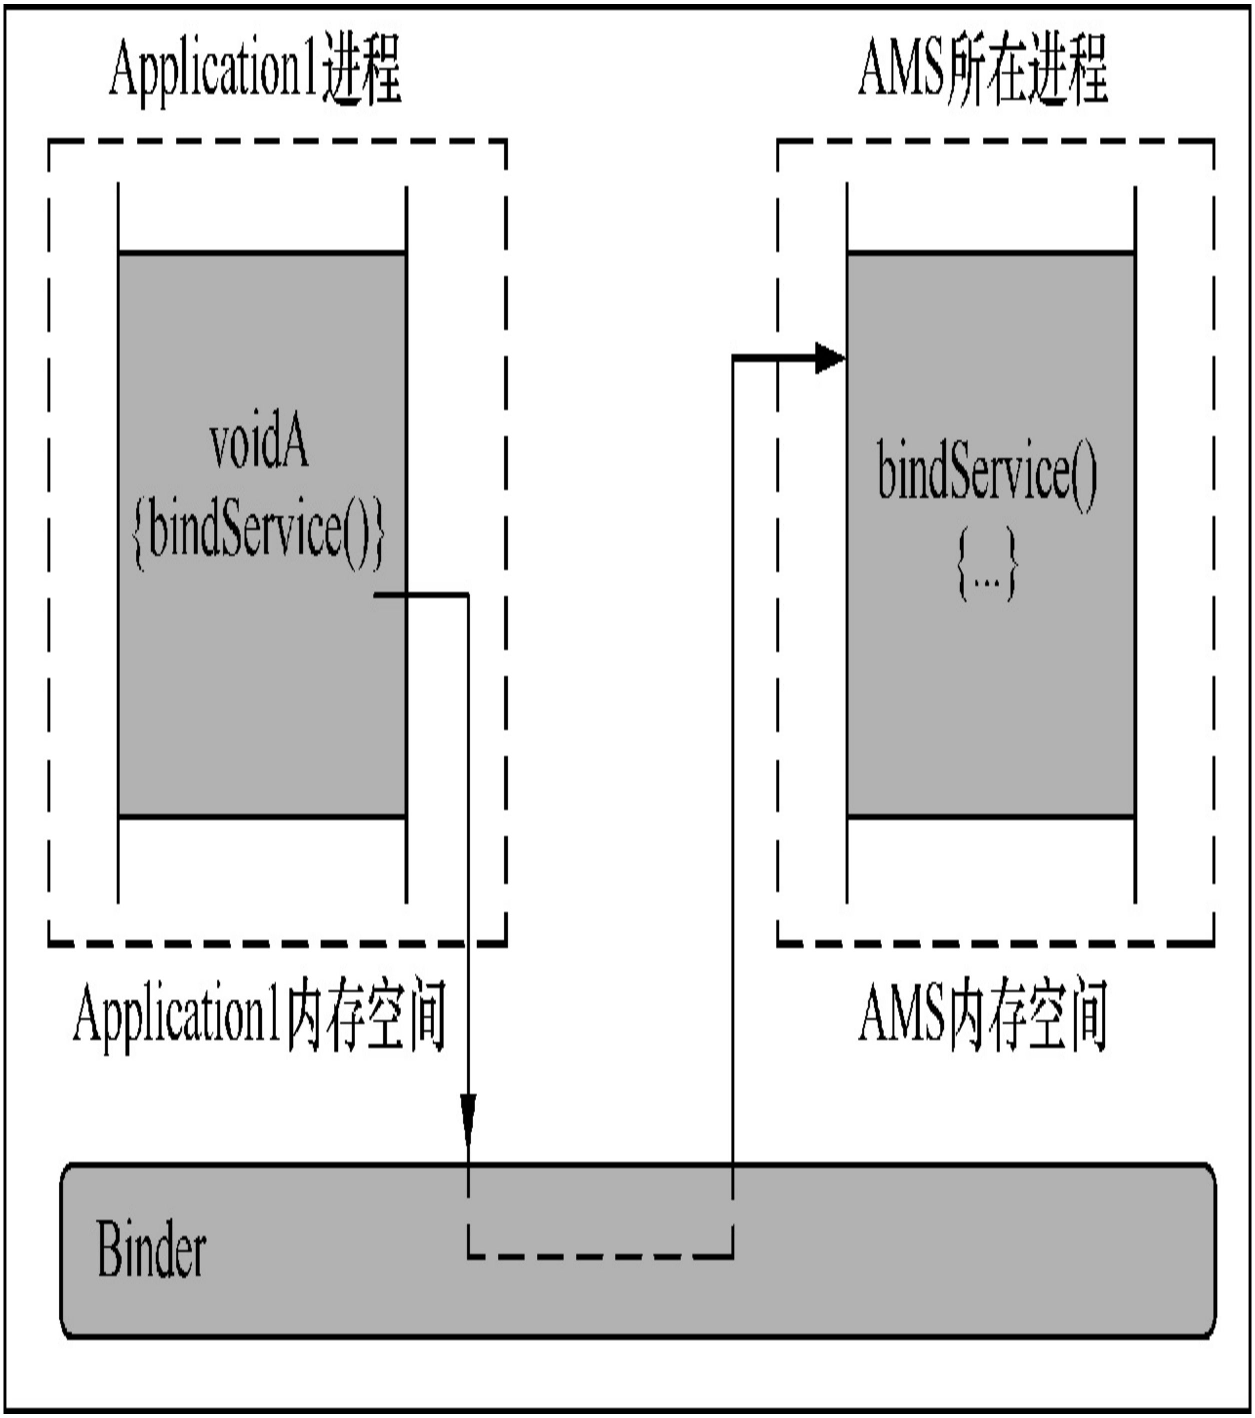

▲图6-3　基于Binder的跨进程内存访问

Binder给人的第一印象是“捆绑者”，即将两个需要建立关系的

object用某些工具束缚在一起。同时，它又是“黏合剂”——正因为有了Binder，Android系统中形形色色的进程与组件才能真正地统一成有机的整体。

简单地说，Binder是Android中使用最广泛的IPC机制。我们在之前的计算机基础章节中已经讲解过操作系统经典的进程间通信方式，如信号量、管道、Socket等。那么，为什么Android还要再自己创造一个新的IPC机制呢？既然Binder可以“力压群雄”而成为主流，必然有其“过人”之处。

本章接下来将为Binder做一个全面而彻底的“体检”：

- Binder驱动；
- Service Manager；
- Binder Client；
- Binder Server。

因为Binder机制涉及的东西既多且杂，根据项目实践中的经验，很多新手往往学习到中途就迷失了方向。为了避免类似情况的发生，我们有必要先讲述下即将登场的几个主角的概念与功能。希望读者可以先了解“它是什么、有哪些组成元素”，进而上升到“为什么会有这些组成、内部原理是什么”。

如果统观Binder中的各个组成元素，就会惊奇地发现它和TCP/IP网络有很多相似之处：

- Binder驱动→路由器；
- Service Manager→DNS；
- Binder Client→客户端；
- Binder Server→服务器。

TCP/IP中一个典型的服务连接过程（比如客户端通过浏览器访问Google主页）如图6-4所示。

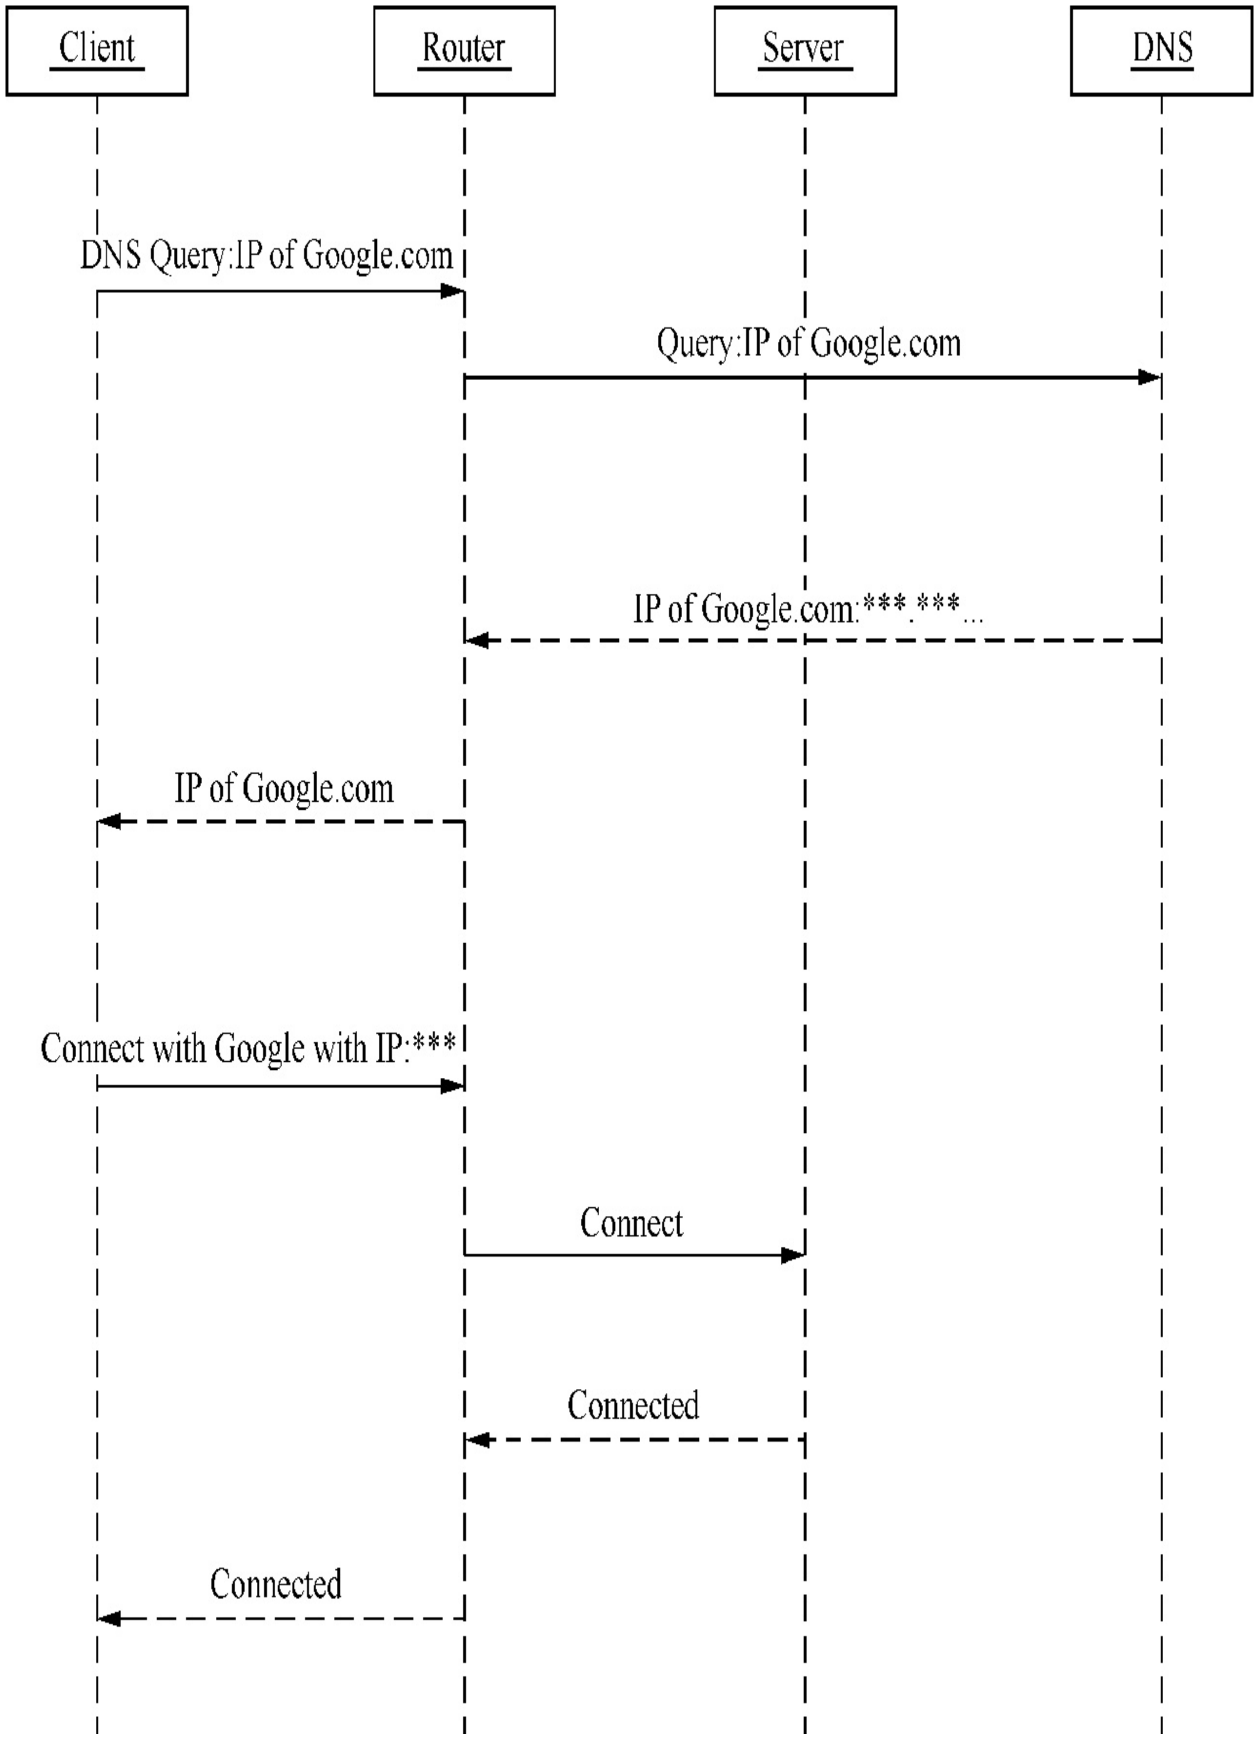
Client
Router
Server
DNS
DNS Query:IP of Google.com
Query:IP of Google.com
IP of Google.com:***.***...
IP of Google.com
Connect with Google with IP:***
Connect
Connected
Connected

▲图6-4　一个典型的TCP/IP访问过程

在这个简化的流程图中共出现了四种角色，即Client，Server，DNS和Router。它们的目标是让Client与Server建立连接，主要分为如下几个步骤。

- Client向DNS查询Google.com的IP地址。

显然，Client一定得先知道DNS的IP地址，才有可能向它发起查询。DNS的IP设置是在客户端接入网络前就完成了的，否则Client将无法正常访问域名服务器。

当然，如果Client已经知晓了Server的IP，那么完全可以跨越这一步而直接与Server连接。比如Windows操作系统就提供了一个hosts文件，用于查询常用网址域名与其IP地址的对应关系。当用户需要访问某个网址时，系统会先从这个文件中判断是否已经存有这个域名的对应IP。如果有就不需要再大费周折地向DNS查询了，从而加快访问速度。

- DNS将查询结果返回Client。

因而Client的IP地址对于DNS也必须是可知的，这些信息都会被封装在TCP/IP包中。

- Client发起连接。
- Client在得到Google.com的IP地址后，就可以据此来向Google服务器发起连接了。

在这一系列流程中，我们并没有特别提及Router的作用。因为它所担负的责任是将数据包投递到用户设定的目标IP中，即Router是整个通信结构中的基础。

从这个典型的TCP/IP通信中，我们还能得到什么提示呢？

首先，在TCP/IP参考模型中，对于IP层及以上的用户来说，IP地址是他们彼此沟通的凭证——任何用户在整个互联网中的IP标志符都是唯一的。

其次，Router是构建一个通信网络的基础，它可以根据用户填写的目标IP正确地把数据包发送到位。

最后，DNS角色并不是必需的，它的出现是为了帮助人们使复杂难记的IP地址与可读性更强的域名建立关联，并提供查询功能。而客户端能使用DNS的前提是它已经正确配置了DNS服务器的IP地址。

清楚了网络通信中各个功能模块所扮演的角色，接下来把它与Binder做一个对比。

Binder的原型如图6-5所示。

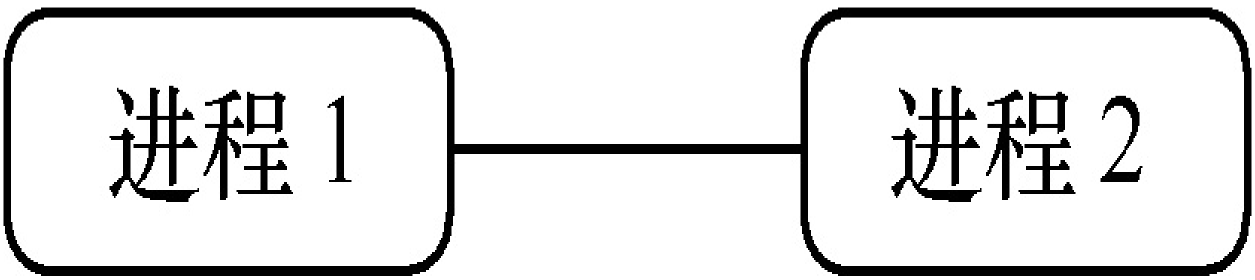

▲图6-5　Binder的原型

Binder的本质目标用一句话来描述，就是进程1（客户端）希望与进程2（服务器）进行互访。但因为它们之间是跨进程（跨网络）的，所以必须借助于Binder驱动（路由器）来把请求正确投递到对方所在进程（网络）中。而参与通信的进程们需要持有Binder“颁发”的唯一标志（IP地址），如图6-6所示。

和TCP/IP网络类似，Binder中的“DNS”也并不是必需的——前提是客户端能记住它要访问的进程的Binder标志（IP地址）；而且要特别注意这个标志是“动态IP”，这就意味着即使客户端记住了本次通信过程中目标进程的唯一标志，下一次访问仍然需要重新获取，这无疑加大了客户端的难度。“DNS”的出现可以完美地解决这个问题，用于管理Binder标志与可读性更强的“域名”间的对应关系，并向用户提供查询功能。

那么在Binder机制中，DNS的角色又由谁来诠释呢?

没错，就是Service Manager，如图6-7所示。

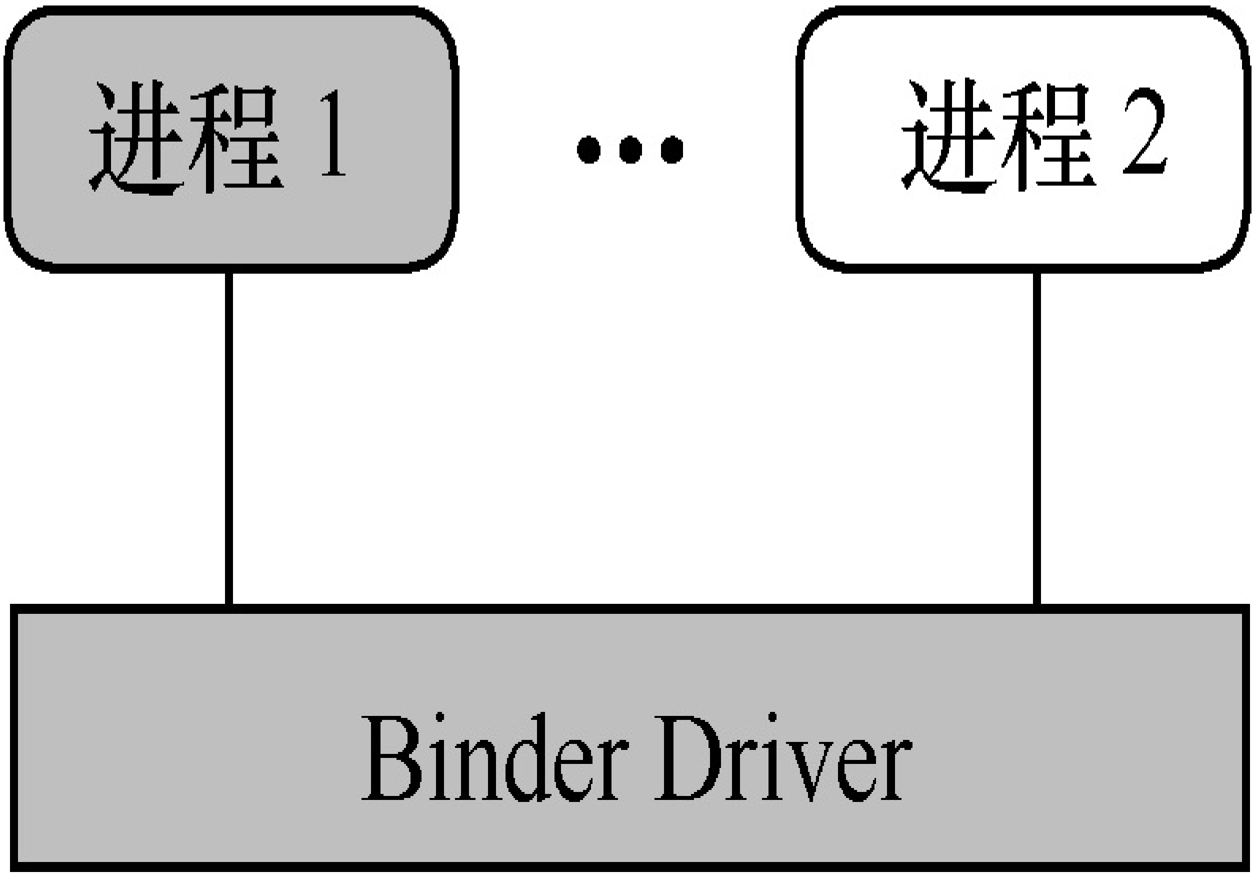

▲图6-6 Binder驱动是进程间“路由”的关键

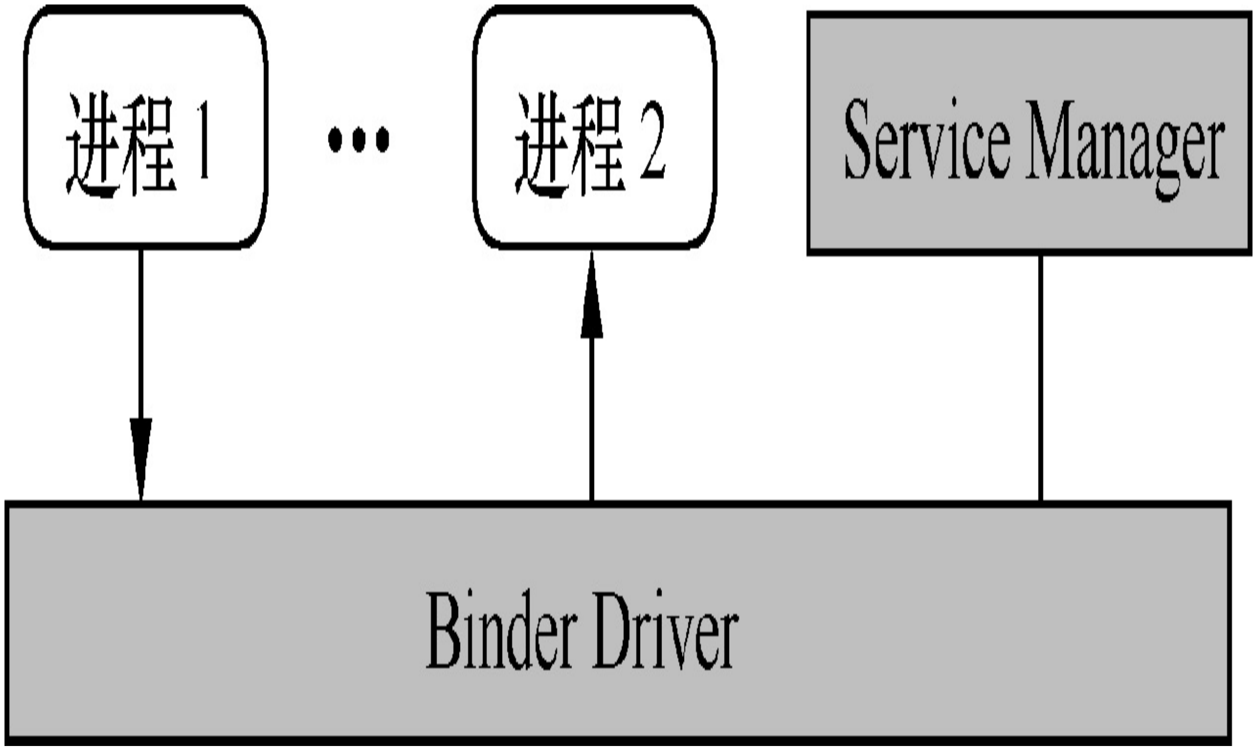

▲图6-7　Service Manager所扮演的角色

读者可能会问，既然Service Manager是DNS，那么它的“IP地址”是什么呢？Binder机制对此做了特别规定。

Service Manager在Binder通信过程中的唯一标志永远都是0。

这样所有问题都解决了。

本章接下来几个小节将逐一深入分析Binder的各组成元素。

6.1 智能指针

智能指针在整个Android工程中使用很广泛，特别是在Binder的源码实现中更可谓“比比皆是”。所以，我们有必要先花费一定的时间来学习它。

6.1.1 智能指针的设计理念

Java和C/C++的一个重大区别，就是它没有“指针”的概念。这并不代表Java不需要使用指针，而是这个“超级武器”被隐藏了起来。“水能载舟，亦能覆舟”，如果读者曾使用C/C++开发过一些大型项目，就会知道开发人员最头疼的事情莫过于概率性极低（Once）的死机问题——而造成系统宕机的根源，往往就是指针异常。所以Java以其他更“安全”的形式向开发人员提供了隐性的“指针”，使得用户既能享受到指针的强大功能，又能尽量避免指针带来的灾难。

C/C++项目中常见的指针问题可以归纳为：

- 指针没有初始化

对指针进行初始化是程序员必须养成的良好习惯，也是指针问题中最容易解决和控制的一个（其实不仅是指针的初始化，新分配的内存块在进行操作前都应视实际情况进行初始化）。

- new了对象后没有及时delete

动态分配的内存对象，其生命周期的控制不当常常会引来不少麻烦。

当代码数量不多而且这些动态对象只由一名程序员自己维护时，问题通常不大，因为只要稍微留心就可以实现new和delete的配套操作；但如果是一个大型工程（特别是多地协同研发的软件项目），由于沟通的不及时或者人员素质的参差不齐，就很可能会出现动态分配的内存没有回收的情况——由此造成的内存泄露问题往往是致命的。

比如FunctionA()中new了一个对象，并作为函数结果返回给调用者，那么原则上这个对象就应该由调用者自行delete。但是由于某些原

因，调用者并没有执行（或者它并不知道要执行）这样的操作，久而久之就会成为系统死机的罪魁祸首。类似的bug因为只在某些特定情况下才会发生（比如内存不足），最后表现出来的问题就是偶发性系统宕机——要彻底找出这类问题的根源很可能会是“大海捞针”。

- 野指针

假设有这样一个场景：我们new了一个对象A，并将指针ptr指向这个新对象（即ptr=new A）。当对A的使用结束后，我们也主动delete了它（delete A），但唯一没做的是将ptr指针置空，那么可能出现什么问题呢?

没错，这就是野指针。因为此时如果有“第三方”试图用ptr来使用内存对象A，它首先通过判断发现ptr并不为空，自然而然地就认为这个对象还是存在的，其结果也将导致不可预料的死机。

还有一种更头疼的情况：假设ptr1和ptr2都指向对象A，后来我们通过ptr1释放了A的内存空间，并且将ptr1也置为null；但是ptr2并不知道它所指向的内存对象已经不存在，此时如果通过ptr2来访问A也会导致同样的问题。

既然C/C++中的指针有如此“洪水猛兽”的倾向，那么我们有没有办法来对它进行适当的改善呢？这就是智能指针出现的意义。

在分析Android中智能指针的实现原理前，读者应该先思考一下——如果让我们自己来设计智能指针，该怎么做呢？

显然，前面提到的指针常见问题点是解决的重点。所以问题就转化为，如何设计一个能有效防止以上几个致命弱点的智能指针方案。

第一个没有初始化的问题很好解决，只要让智能指针在创建时置为null即可。

第二个问题是实现new和delete的配套。换句话说，new了一个对象就需要在某个地方及时地delete它。既然是智能的指针，那就意味着它应该是一个默默奉献的辛勤工作者，尽可能自动地帮程序员排忧解难，而不是所有事情都需要程序员手工来完成。

要让智能指针自动判断是否需要回收一块内存空间，应该如何设计？

以下我们称内存对象为object，称智能指针为SmartPointer，那么：

- SmartPointer是个类

首先能想到的是，SmartPointer要能记录object的内存地址。也就是说，它的内部应该有一个指针变量指向object，所以SmartPointer是一个类。即：

```
class SmartPointer
{
private:
     void *  m_ptr; //指向object对象
}
```

- SmartPointer是一个模板类

智能指针并不是针对某种特定类型的对象设计的，因而一定是模拟类。具体如下所示：

```
template <typename T>
class SmartPointer
{
private:
     T*  m_ptr;//指向object对象
}
```

- SmartPointer的构造函数

根据第一个问题的描述，智能指针的构造函数应将m_ptr置空。具体如下所示：

```
template <typename T>
class SmartPointer
{
     inline  SmartPointer() : m_ptr(0) { }
     private:
          T*  m_ptr;//将指向object
}
```

- 引用计数

这是关键的问题点，智能指针怎么知道应该在什么时候释放一个内存对象呢？答案就是“当不需要的时候”释放——这听起来像一句废话，却引导我们从“什么是需要和不需要”这个入口点来思考问题：假设有一个指针指向这个object，那就必然代表后者是“被需要”的；直到这个指针解除了与内存对象的关系，我们就可以认为这个内存对象已经“不被需要”。

如果有两个以上的指针同时使用内存对象呢？也好办，只要有一个计数器记录着该内存对象“被需要”的个数即可。当这个计数器递减到零时，就说明该内存对象应该“寿终正寝”了。这就是在很多领域都获得了广泛应用的“引用计数”的概念。

不过又有一个问题点接踵而至，那就是由谁来管理这个计数器。

下面我们设计两种计数器管理方式，大家可以比较下它们的优缺点。

1．计数器由智能指针拥有

这时的情况如图6-8所示。

如果当前只有一个智能指针引用了object，看上去并没有什么大问题。那么，如果有两个（或以上）的智能指针都需要使用object呢？如图6-9所示。

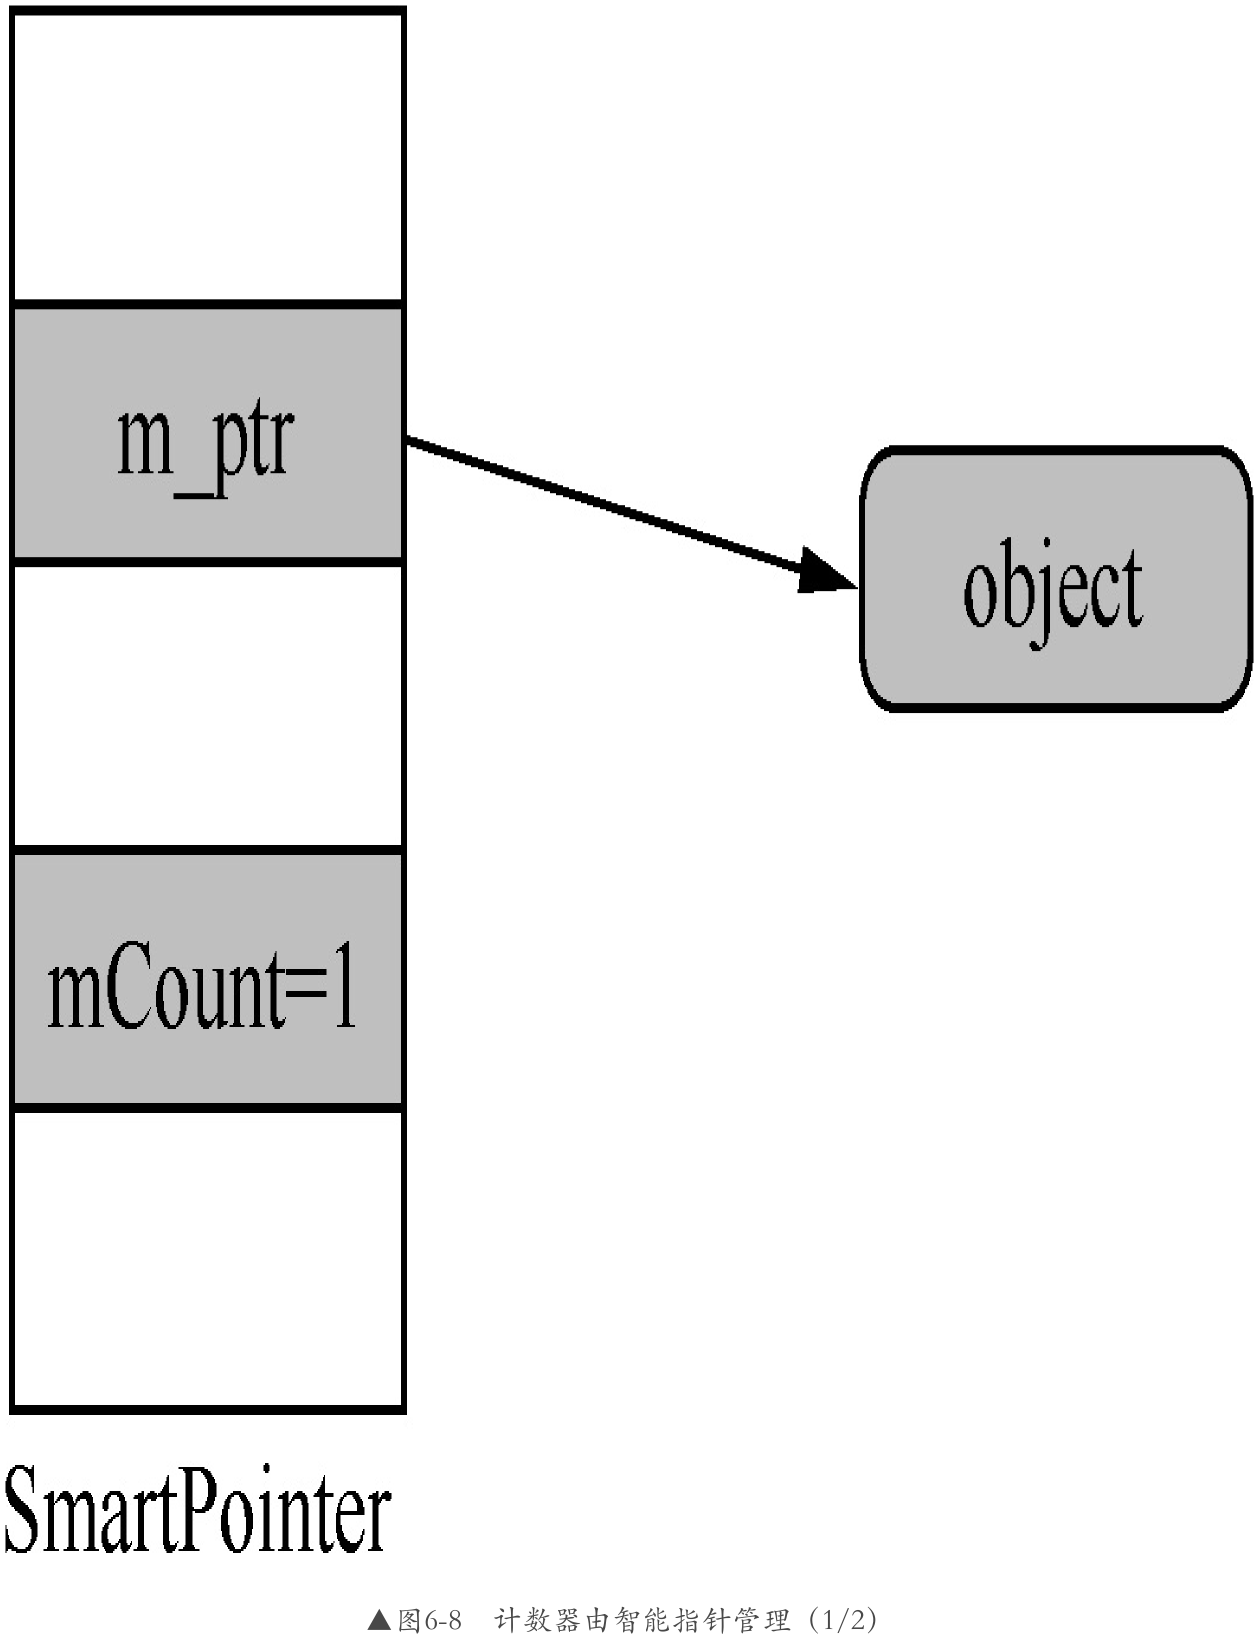

▲图6-8　计数器由智能指针管理（1/2）

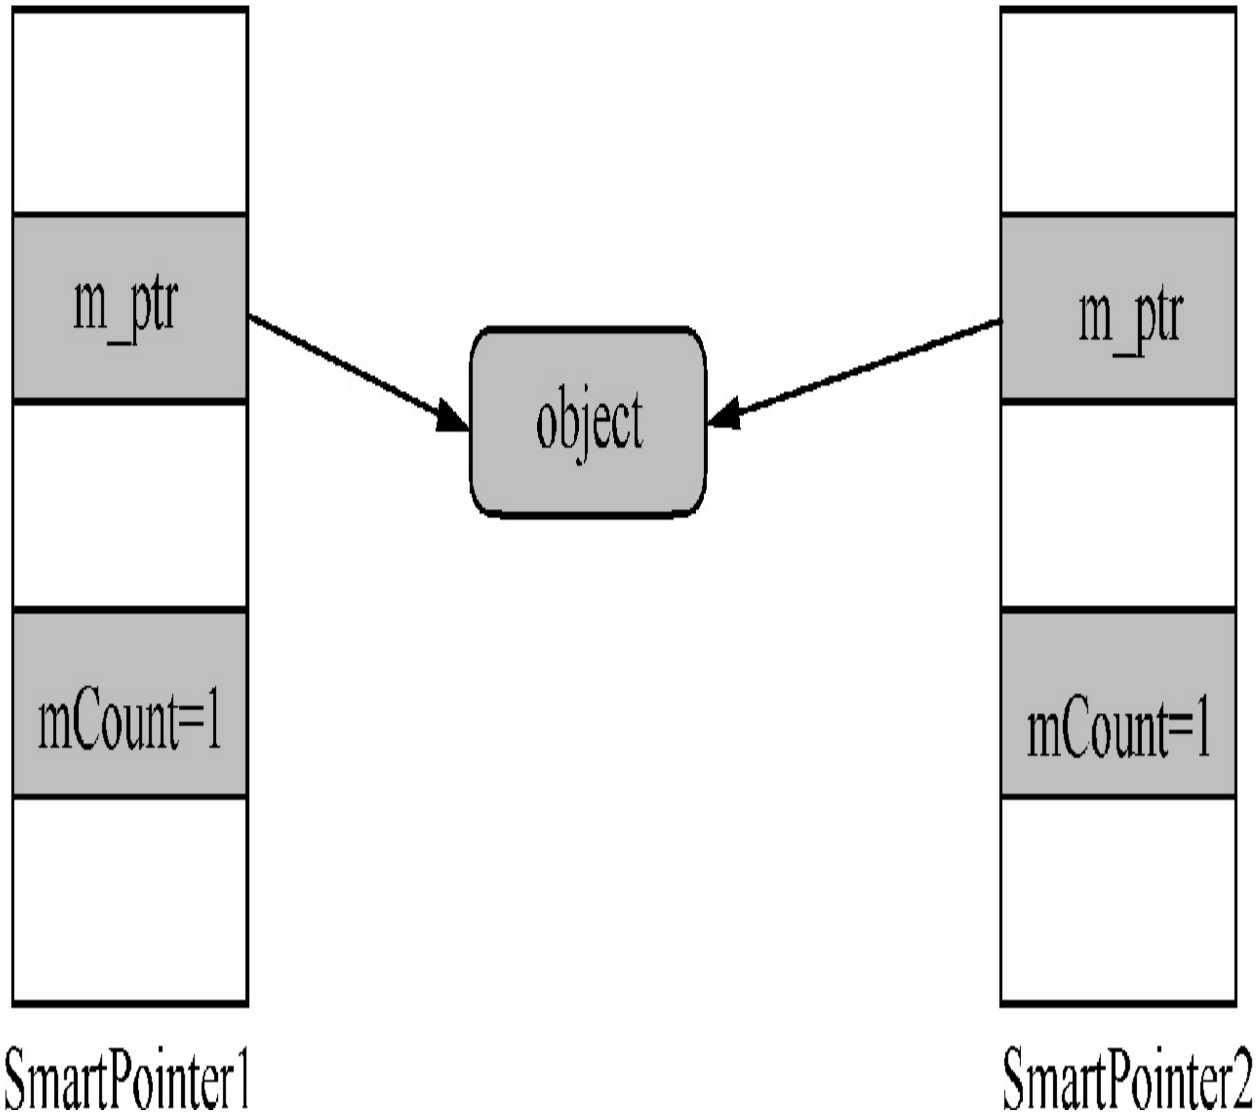

▲图6-9　计数器由智能指针管理（2/2）

当SmartPointer1释放了自己与object的连接后，会将mCount减1——这时候发现计数值已经为零，所以根据设计需要去delete object。然而令SmartPointer1意想不到的情况是此时SmartPointer2却还在使用object——显然这将引发致命的问题。

2．解决这一问题的唯一方法——计数器由object自身持有

我们可以为有计数器需求的内存对象实现一个统一的“父类”——这样只要object继承于它就具备了计数的功能。比如下面的范例：

```
template <class T>
```

```
class LightRefBase
{
public:
    inline LightRefBase() : mCount(0) { }
    inline void incStrong() const {/*增加引用计数*/
        android_atomic_inc(&mCount);
    }
    inline void decStrong() const {/*减小引用计数*/
        if (android_atomic_dec(&mCount) == 1) {
            delete static_cast<const T*>(this);/*删除内存对象*/
        }
    }
protected:
    inline ~LightRefBase() { }

private:
    mutable volatile int32_t mCount;/*引用计数值*/
};
```

以上代码段中的LightRefBase类主要提供了两个方法，即incStrong和decStrong，分别用于增加和减少引用计数值；而且如果当前已经没有人引用内存对象（计数值为0），它还需要自动释放自己。

那么，incStrong和decStrong这两个函数在什么情况下会被调用呢？既然是引用计数，当然是在“被引用时”，所以这个工作应该由SmartPointer完成。如下所示：

```
SmartPointer<TYPE>    smartP = new object;
```

当一个智能指针引用了object时，其父类中的incStrong就会被调用。这也意味着SmartPointer必须要重载它的“=”运算符（注意：多数情况下只重载“等号”是不够的，应视具体设计需求而定）：

```
template <typename T>
class SmartPointer
{
     inline  SmartPointer() : m_ptr(0) { }
     ~wp();
     SmartPointer& operator = (T* other);//重载运算符

private:
     T*  m_ptr;//指向object对象
}
```

```
template<typename T>
SmartPointer<T>&SmartPointer<T>::operator = (T* other)
{
     if(other != null)
     {
          m_ptr = other;/*指向内存对象*/
          other-> incStrong();/*主动增加计数值*/
     }
     return *this;
}
```

当SmartPointer析构时，也应该及时调用decStrong来释放引用：

```
template<typename T>
wp<T>::～wp()
{
    if (m_ptr)m_ptr->decStrong();
}
```

经过以上分析后，我们将前一个示意图进行调整，具体如图6-10所示。

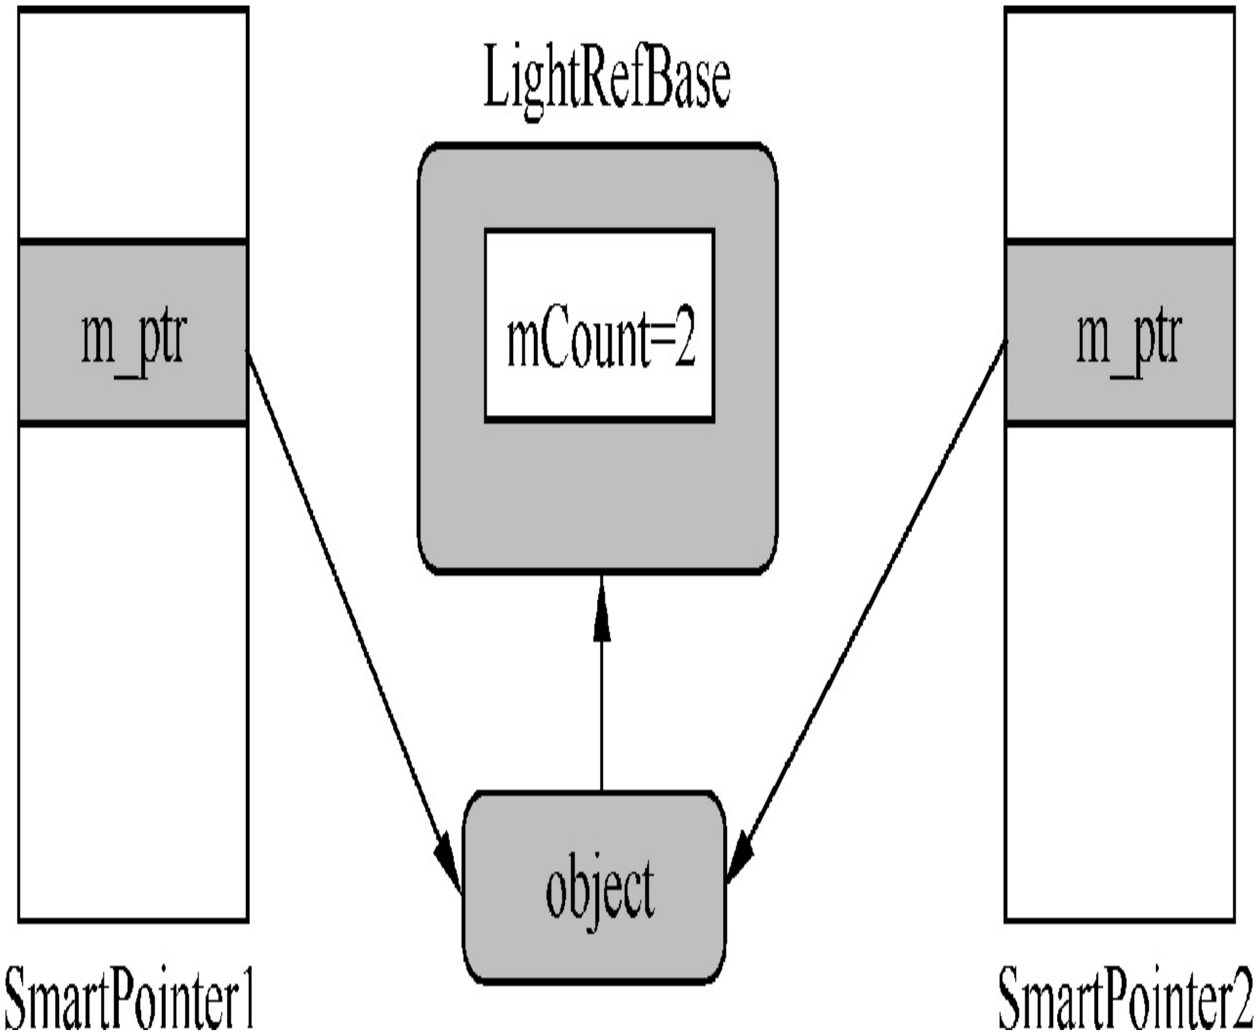

▲图6-10　引用计数器由内存对象管理

解决了第二个问题，实际上第三个问题也就迎刃而解了。引用计数器的出现使得释放内存对象不再是个别指针的事情，而是对象自己的“内政”——只要有人在使用，它就不会轻易delete自身，也就有效地避免了引用它的指针突然变成“野指针”的情况。

理解了本小节讲解的这些基础知识后，接下来将具体分析Android中的智能指针实现，包括强指针和弱指针两种。

6.1.2　强指针sp

看到sp很多人会以为是SmartPointer的缩写，而实际上它是StrongPointer的简写。与sp相对应的另一个类是wp（即

WeakPointer），我们将在下一小节中分析。

经过几次系统改版后，sp这个类已经被完全移出了RefBase.h文件（因而不少读者反映找不到定义sp的地方）。最新源码工程中sp类的位置在：

frameworks/native/include/utils/StrongPointer.h

而wp以及前一小节所讲述的LightRefBase都仍在RefBase.h中。

下面来看看sp类中一些重要的接口实现：

```
template <typename T>
class sp
{
public:
    inline sp() : m_ptr(0) { }

    sp(T* other);/*常用构造函数*/
    …/*其他构造函数*/
    ～sp();/*析构函数*/
    sp& operator = (T* other);// 重载运算符“=”
    …
    inline  T&      operator* () const  { return *m_ptr; }// 重载运
    inline  T*      operator-> () const { return m_ptr;  }// 重载运
    inline  T*      get() const         { return m_ptr; }
    …
private:
    template<typename Y> friend class sp;
    template<typename Y> friend class wp;
    void set_pointer(T* ptr);
    T* m_ptr;
};
```

大家可能已经注意到了，它和前一小节的SmartPointer类在实现上基本是一致的。比如运算符等号的实现为：

```
template<typename T>
sp<T>& sp<T>::operator = (T* other)
{
    if (other) other->incStrong(this);/*增加引用计数*/
    if (m_ptr) m_ptr->decStrong(this);
    m_ptr = other;
    return *this;
}
```

上面这段代码同时考虑了对一个智能指针重复赋值的情况。即当m_ptr不为空时，要先撤销它之前指向的内存对象，然后才能赋予其新值。

另外，为sp分配一个内存对象并不一定要通过操作运算符（如等号），它的构造函数也是可以的：

```
template<typename T>
sp<T>::sp(T* other)
: m_ptr(other)
{
    if (other) other->incStrong(this);/*因为是构造函数，不用担心m_ptr
}
```

这时m_ptr就不用先置为null，可以直接指向目的对象。

而析构函数的做法和我们的预想也是一样的：

```
template<typename T>
sp<T>::~sp()
{
    if (m_ptr) m_ptr->decStrong(this);
}
```

总的来说，强指针sp的实现和前一小节的例子基本相同，此处不再赘述。

6.1.3　弱指针wp

前面在阐述智能指针的“设计理念”时，其实是以强指针为原型逐步还原出了智能指针作者的“意图”，那么弱指针又是什么呢？

读者可以想象这样一个场景：父对象parent指向子对象child，然后子对象又指向父对象，这就存在了循环引用的现象。

比如有如下两个class：

```
struct CDad
{
    CChild *myChild;
};
```

```
struct CChild
{
    CDad  *myDad;
};
```

那么，它们很可能会产生如图6-11所示的关系。

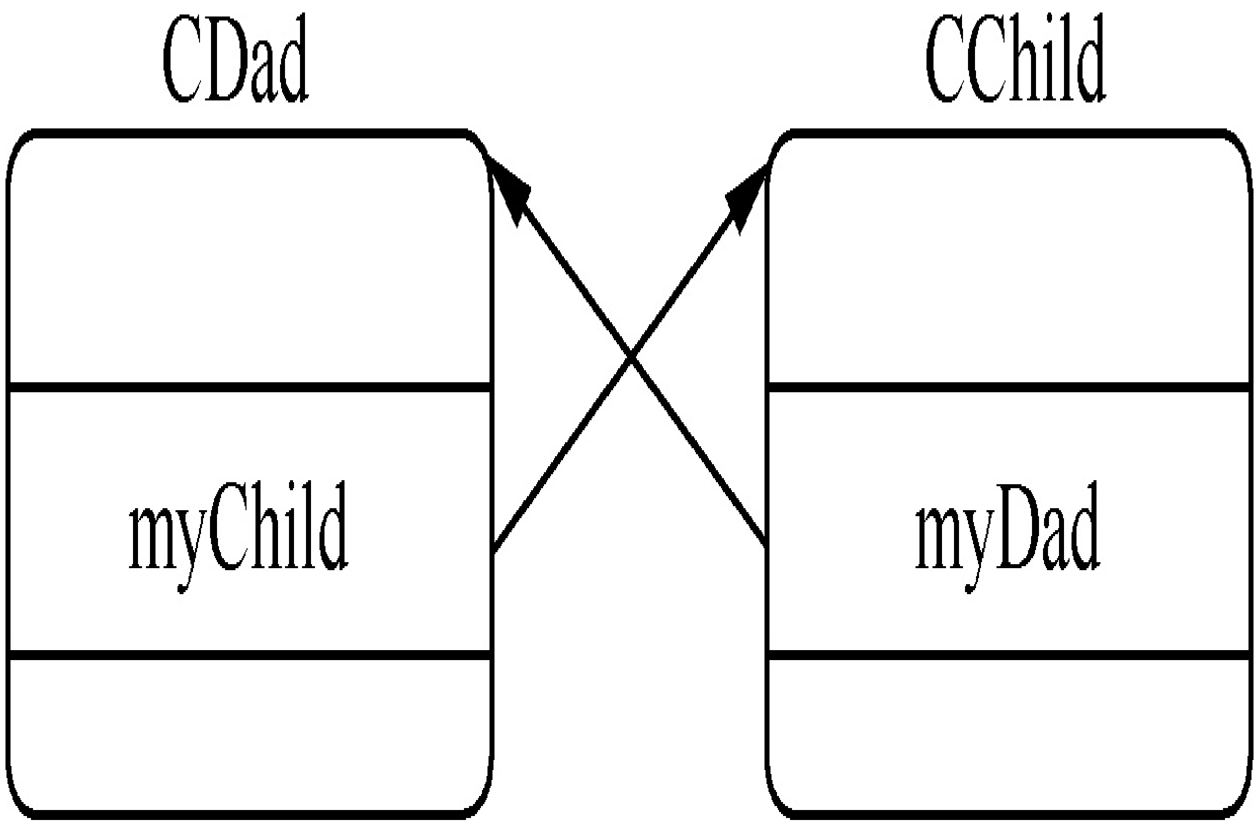

▲图6-11　对象间互相引用的情况

如果不考虑智能指针，这样的情况并不会导致任何问题（而且在项目开发过程中也并不少见）。但是在智能指针的场景下，有没有特别要注意的地方呢？

假设这两个类都具有引用计数器的功能。

- 因为CDad指向了CChild，所以后者的引用计数器不为零。
- 而CChild又指向了CDad，同样也会使它的计数器不为零。

这有点类似于操作系统中的死锁——因为内存回收者发现两者都是处于“被需要”的状态，当然不能释放，从而形成了恶性循环。

解决这个矛盾的一种有效方法是采用“弱引用”。具体措施如下。

CDad使用强指针来引用CChild，而CChild只使用弱引用来指向父类。双方规定当强引用计数为0时，不论弱引用是否为0都可以delete自己（在Android系统中这个规则是可以调整的，后面会介绍）。这样只要有一方得到了释放，就可以成功避免死锁。聪明的你一定能马上想到另一种可能，即会不会导致野指针的问题。没错，的确会有这方面的顾虑。比如CDad因为强指针计数已经到0，根据规则生命周期就结束了；但此时CChild还持有其父类的弱引用，显然如果CChild此时用这个指针来访问CDad将引发致命的问题。鉴于此，我们还要特别规定：

弱指针必须先升级为强指针，才能访问它所指向的目标对象。

弱指针的主要使命就是解决循环引用的问题。下面具体看看它和强指针有什么区别：

```
template <typename T>
class wp
{
public:
    typedef typename RefBase::weakref_type weakref_type;

    inline wp() : m_ptr(0) { }

    wp(T* other);//构造函数
    …/*其他构造函数省略*/
    ~wp();
    wp& operator = (T* other);//运算符重载
    …
    void set_object_and_refs(T* other, weakref_type* refs);
    sp<T> promote() const;/*升级为强指针*/
    …/*其他方法省略*/

private:
    template<typename Y> friend class sp;
    template<typename Y> friend class wp;

    T*              m_ptr;
    weakref_type*   m_refs;
};
```

和sp相比，wp在类定义上有如下重要区别。

- 除了指向目标对象的m_ptr外，wp另外有一个m_refs指针，类型为weakref_type。
- 没有重载->，*等运算符。
- 有一个prmote方法来将wp提升为sp。
- 目标对象的父类不是LightRefBase，而是RefBase。

注意

这并不是说sp不能用RefBase，要视具体情况而言。

先来看看它的构造函数，再有针对性地解释上面所列的几点：

```
template<typename T>
wp<T>::wp(T* other)
    : m_ptr(other)
{
    if (other) m_refs = other->createWeak(this);
}
```

可以和强指针中的构造方法进行对比，如下所示：

```
if (other) other->incStrong(this);
```

可见wp并没有直接增加目标对象的引用计数值，而是调用了createWeak方法。这个函数属于前面提到的RefBase类，如下所示：

```
class RefBase
{
public:
     void incStrong(const void* id) const;/*增加强引用计数值*/
     void decStrong(const void* id) const;/*减少强引用计数值*/
    …
    class weakref_type  //嵌套类，wp中用到的就是这个类
    {
    public:
          RefBase* refBase() const;
          void incWeak(const void* id);/*增加弱引用计数值*/
          void decWeak(const void* id);/*减少弱引用计数值*/
```

```
        …
    };
     weakref_type*   createWeak(const void* id) const;/*生成一个wea
     weakref_type*   getWeakRefs() const;
     …
     typedef RefBase basetype;

protected:
                         RefBase();/*构造函数*/
     virtual             ～RefBase();/*析构函数*/

    //以下参数用于修改object的生命周期
     enum {
         OBJECT_LIFETIME_STRONG  = 0x0000,
         OBJECT_LIFETIME_WEAK    = 0x0001,
         OBJECT_LIFETIME_MASK    = 0x0001
     };
     …
     weakref_impl* const mRefs;
};
```

RefBase嵌套了一个重要的类weakref_type，也就是前面m_refs指针所属的类型。RefBase中还有一个mRefs的成员变量，类型为weakref_impl。从名称上来看，它应该是weakref_type的实现类。如下（分段阅读）：

```
/*frameworks/native/libs/utils/RefBase.cpp*/
class RefBase::weakref_impl : public RefBase::weakref_type //确实是
{
public:
    volatile int32_t    mStrong;/*强引用计数值*/
    volatile int32_t    mWeak;/*弱引用计数值*/
    RefBase* const    mBase;
    volatile int32_t    mFlags;
#if !DEBUG_REFS/*不是debug的情况下*/
    weakref_impl(RefBase* base): mStrong(INITIAL_STRONG_VALUE), m
        , mBase(base), mFlags(0)
    {
    }
    void addStrongRef(const void* /*id*/) { }
    void removeStrongRef(const void* /*id*/) { }
    …
#else  // DEBUG_REFS宏，即debug的情况下
    weakref_impl(RefBase* base)
        : mStrong(INITIAL_STRONG_VALUE), mWeak(0), mBase(base), m
        , mStrongRefs(NULL), mWeakRefs(NULL)
```

```
        , mTrackEnabled(!!DEBUG_REFS_ENABLED_BY_DEFAULT), mRetain
    {
    }
    …
#endif  // DEBUG_REFS宏结束
}; // RefBase::weakref_impl类结束
```

从开头的几个变量可以大概猜出weakref_impl所做的工作，其中mStrong用于强引用计数，mWeak用于弱引用计数。

宏DEBUG_REFS用于指示release或debug版本。可以看到在release版本下，addStrongRef，removeStrongRef等与Ref相关的一系列方法都没有具体实现。也就是说，这些方法实际上是用于调试的，我们在分析时完全可以不用理会。这样一来整个分析也明朗了很多，笔者认为这几个类的写法还是有商榷的余地。

Debug和Release版本都将mStrong初始化为INITIAL_STRONG_VALUE。这个值的定义如下：

```
#define INITIAL_STRONG_VALUE (1<<28)
```

而mWeak则初始化为0。

上面#else到#endif之间的部分都是debug版本要做的工作，所以都可以略过不看。因而上述代码段中并没有引用计数器相关的控制实现，真正有用的代码在类声明的外面。比如我们在wp构造函数中遇到的createWeak函数：

```
RefBase::weakref_type* RefBase::createWeak(const void* id) const
{
    mRefs->incWeak(id);/*增加弱引用计数*/
    return mRefs;/*直接返回weakref_type对象*/
}
```

这个函数先增加了mRefs（也就是weakref_impl类型的成员变量）中的弱引用计数值，然后返回这个mRefs。

相信很多人已经有点迷糊了，其关系如图6-12所示。

首先wp中的m_ptr还是要指向目标对象（继承自RefBase）。RefBase的作用类似于设计小节中讨论的LightRefBase，只不过它还同

时提供了弱引用控制以及其他新的功能。

和LightRefBase不同，RefBase不是直接使用int变量来保存引用计数值，而是采用了weakref_type类型的计数器。这也是可以理解的，因为RefBase需要处理多种计数类型。另外，wp中也同时保存了这个计数器的地址，也就是wp中的m_refs和RefBase中的mRefs都指向了计数器。其中wp是通过在构造函数中调用目标对象的createWeak来获得计数器地址的，而计数器本身是由RefBase在构造时创建的。

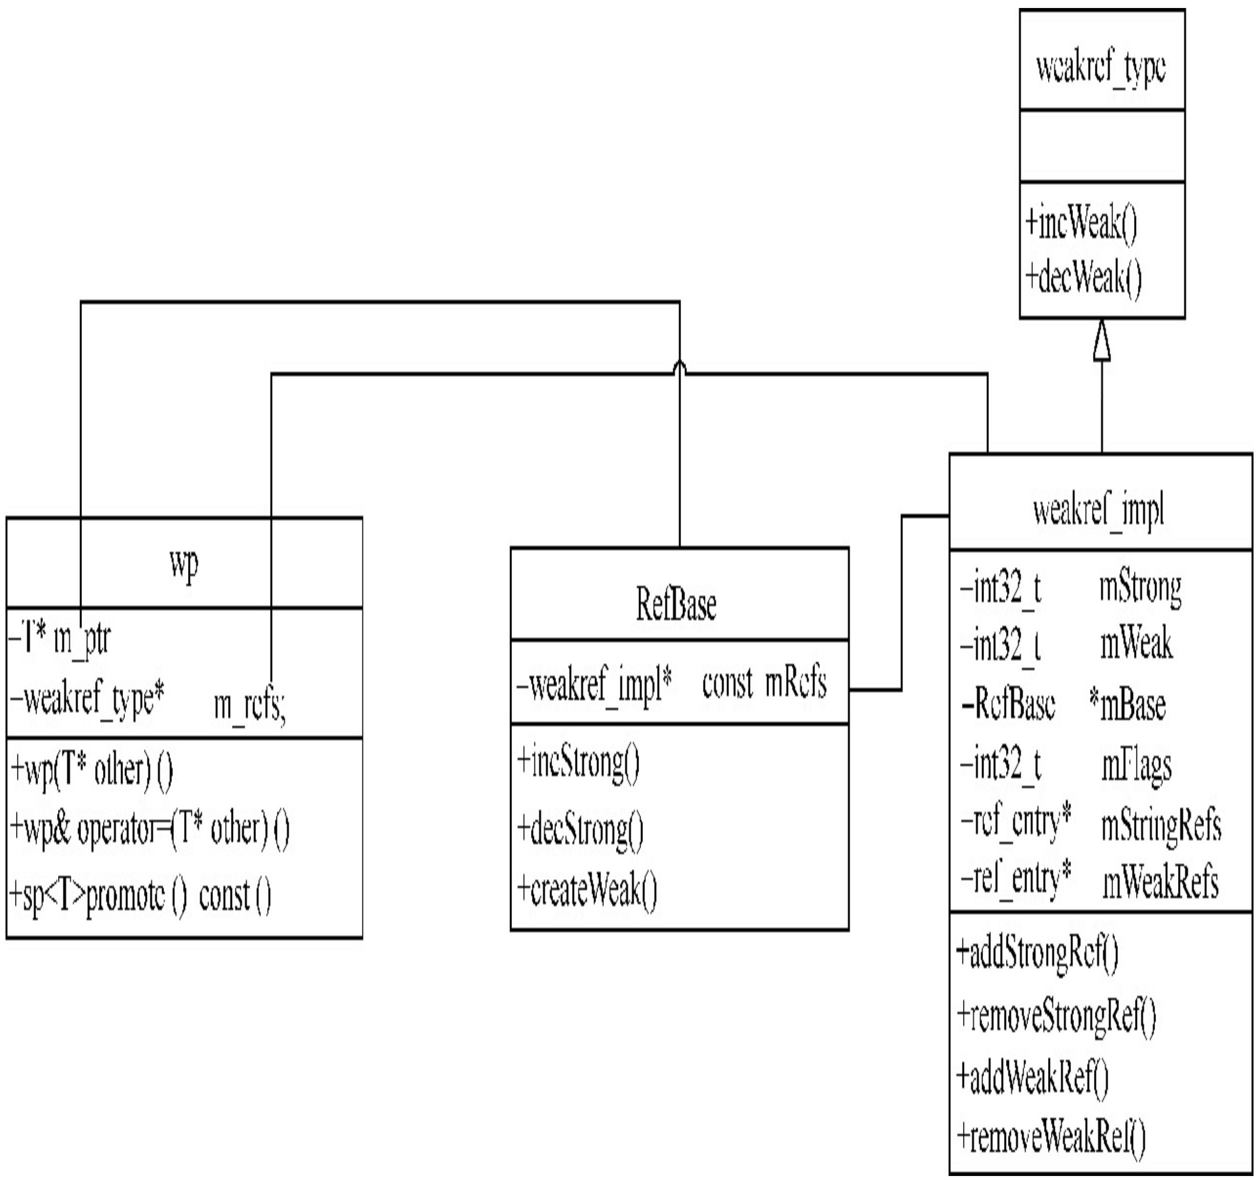

▲图6-12　弱指针机制中各主要类的关系

整个wp机制看起来很复杂，但与强指针相比实际上只是启用了一个新的计数器weakref_impl而已，其他所有工作都是围绕如何操作这个计数器而展开的。因而接下来的重点就是看看这几个类是如何利用新计数器来达到设计目标的。

需要强调的是，虽然weakref_impl是RefBase的成员变量，但是wp也可以直接控制它，所以整个逻辑显得稍微有点混乱，不知道是不是为了兼容以前版本而遗留下来的问题。

在createWeak中，mRefs通过incWeak增加了计数器的弱引用。即：

```
void RefBase::weakref_type::incWeak(const void* id)
{
    weakref_impl* const impl = static_cast<weakref_impl*>(this);
    impl->addWeakRef(id);/*用于调试目的*/
    const int32_t c = android_atomic_inc(&impl->mWeak);
    ALOG_ASSERT(c >= 0, "incWeak called on %p after last weak ref
}
```

这个函数真正有用的语句就是android_atomic_inc(&impl->mWeak)，它增加了mWeak计数器值，而其他部分都与调试相关，我们一概略过。

这样当wp构造完成以后，RefBase所持有的weakref_type计数器中的mWeak就为1。后面如果有新的wp指向这个目标对象，mWeak还会持续增加。而如果是sp指向它呢？

我们在上一小节中分析过，这时sp会调用目标对象的incStrong方法来增加强引用计数值。当目标对象继承自RefBase时，这个函数的实现是：

```
void RefBase::incStrong(const void* id) const
{
    weakref_impl* const refs = mRefs;
    refs->incWeak(id);/*增加弱引用计数值*/

    refs->addStrongRef(id);
    const int32_t c = android_atomic_inc(&refs->mStrong);/*增加强引
    ALOG_ASSERT(c > 0, "incStrong() called on %p after last stron
    if (c != INITIAL_STRONG_VALUE)  { //判断是不是第一次
        return;/*不是第一次，直接返回*/
    }
```

```
    android_atomic_add(-INITIAL_STRONG_VALUE, &refs->mStrong);
    refs->mBase->onFirstRef();
}
```

首先剔除与调试相关的语句，真正的操作如下：

```
refs->incWeak(id);
const int32_t c = android_atomic_inc(&refs->mStrong);
```

也就是同时增加弱引用和强引用计数值。然后还要判断目标对象是不是第一次被引用，其中的c变量得到的是“增加之前的值”，因而如果等于INITIAL_STRONG_VALUE就说明是第一次——这时候一方面要回调onFirstRef通过对象自己被引用，另一方面要对mStrong值做下小调整。为什么呢？

我们知道，mStrong先是被置了INITIAL_STRONG_VALUE= 1<<28，那么当第一次增加时，它就是1<<28+1，所以还要再次减掉INITIAL_STRONG_VALUE才能得到1。

看完强弱指针对计数器的操作后，我们再来分析下目标对象在什么情况下会被释放。无非就是考查减少强弱引用时系统所遵循的规则，如下所示是decStrong的情况：

```
void RefBase::decStrong(const void* id) const
{
    weakref_impl* const refs = mRefs;
    refs->removeStrongRef(id);/*调试目的*/
    const int32_t c = android_atomic_dec(&refs->mStrong);/*减少强引
    ALOG_ASSERT(c >= 1, "decStrong() called on %p too many times"
    if (c == 1) {/*减少后强引用计数值已经降为0*/
        refs->mBase->onLastStrongRef(id);/*通知事件*/
        if ((refs->mFlags&OBJECT_LIFETIME_MASK) ==OBJECT_LIFETIME
            delete this;/*删除对象*/
        }
    }
    refs->decWeak(id);/*减少弱引用计数*/
}
```

首先减少mStrong计数器，如果发现已经减到0（即c==1），就需要回调onLastStrongRef通知这一事件，接着执行删除操作（如果标志是OBJECT_LIFETIME_STRONG的话）。

特别要注意，减小强引用计数值时还要同时减小弱引用计数值，即最后的decWeak(id)。其实现如下（分两段阅读）：

```
void RefBase::weakref_type::decWeak(const void* id)
{
    weakref_impl* const impl = static_cast<weakref_impl*>(this);
    impl->removeWeakRef(id);/*调试目的*/
    const int32_t c = android_atomic_dec(&impl->mWeak);/*减小弱引用
    ALOG_ASSERT(c >= 1, "decWeak called on %p too many times", th
    if (c != 1) return;
```

先减小mWeak计数值，如果发现还不为0（即c!=1），就直接返回；否则就是弱引用计数值也为0，此时要根据LIFETIME标志分别处理：

```
    if ((impl->mFlags&OBJECT_LIFETIME_WEAK) ==OBJECT_LIFETIME_STR
        if (impl->mStrong == INITIAL_STRONG_VALUE) {
            delete impl->mBase;
        } else {
            delete impl;
        }
    } else {
        impl->mBase->onLastWeakRef(id);
        if ((impl->mFlags&OBJECT_LIFETIME_MASK) ==OBJECT_LIFETIME
              delete impl->mBase;
        }
    }
}
```

上面这段代码是弱引用的处理核心，主要基于以下标志来处理。

```
    enum {
        OBJECT_LIFETIME_STRONG  = 0x0000,
        OBJECT_LIFETIME_WEAK    = 0x0001,
        OBJECT_LIFETIME_MASK    = 0x0001
    };
```

每个目标对象都可以通过以下方法来更改它的引用规则。

```
void RefBase::extendObjectLifetime(int32_t mode)
{
    android_atomic_or(mode, &mRefs->mFlags);
}
```

实际上就是改变了mFlags标志值——默认情况下它是0，即

OBJECT_LIFETIME_STRONG。

所以当(impl->mFlags&OBJECT_LIFETIME_WEAK) == OBJECT_LIFETIME_STRONG时，即释放规则受强引用控制的情况。有的读者可能会想，既然是强引用控制，那弱引用还要做什么工作呢？理论上它确实可以直接返回了，不过还有些特殊情况。前面在incStrong函数里，我们看到它同时增加了强、弱引用计数值。而增加弱引用时是不会同时增加强引用的，这说明弱引用的值一定会大于等于强引用值。当程序走到这里，弱引用计数值一定为0，而强引用值有两种可能。

一种是强引用值为INITIAL_STRONG_VALUE，说明这个目标对象没有被强引用过，也就是说没有办法靠强指针来释放目标，所以需要delete impl->mBase。

另一种就是在有强引用的情况下，此时要delete impl，而目标对象会由强引用的decStrong来释放。

那么，为什么是在这里delete这个计数器呢？weakref_impl既然是由RefBase创建的，那么按理来说也应该由它来删除。实际上RefBase也想做这个工作，只是力不从心。其析构函数如下：

```
RefBase::～RefBase()
{
     …
     if (mRefs->mWeak == 0) {
          delete mRefs;
     }
}
```

在这种情况下，RefBase既然是由decStrong删除的，那么从上面decStrong的执行顺序上来看mWeak值还不为0，因而并不会被执行。

如果是弱引用控制下的判断规则（即OBJECT_LIFETIME_WEAK），其实和decStrong中的处理一样，要首先回调通知目标对象这一事件，然后才能执行删除操作。

到此我们就分析完Android系统中的智能指针源码实现了，小结如下。

- 智能指针分为强指针sp和弱指针wp两种。

- 通常情况下目标对象的父类是RefBase——这个基类提供了一个weakref_impl类型的引用计数器，可以同时进行强弱引用的控制（内部由mStrong和mWeak提供计数）。
- 当incStrong增加强引用的，也会增加弱引用。
- 当incWeak时只增加弱引用计数。
- 使用者可以通过extendObjectLifetime设置引用计数器的规则，不同规则下对删除目标对象的时机判断也是不一样的。
- 使用者可以根据程序需求来选择合适的智能指针类型和计数器规则。

6.2　进程间的数据传递载体——Parcel

大家有没有思考过，进程间该如何传递数据的。

下面先来列举生活中的两个例子，以供读者对比参考。

例1．快递包裹

比如从深圳快递一件衣服给北京的朋友，有哪些方法呢？显然途径是比较多的。但无论是空运还是汽车、火车运输，在整个传递过程中“衣服”本身始终是没有变过的——朋友拿到的衣服还是原来那件。

例2．通过电子邮件发送图片

假设你在深圳通过电子邮件给北京的朋友发送了一张“衣服的图片”，那么当朋友看到它时，已经无法估计这张图片数据在传输过程中被复制过多少次了——但是可以肯定的是，他看到的图像和原始图片绝对是一模一样的。

显然进程间的数据传递和例2属于同一种情况，不过略有区别。

如果只是一个int型数值，不断复制直到目标进程即可。但如果是某个对象呢？我们可以想象下，同一进程间的对象传递都是通过引用来做的，因而本质上就是传递了一个内存地址。这种方式在跨进程的情况下就无能为力了。由于采用了虚拟内存机制，两个进程都有自己独立的内存地址空间，所以跨进程传递的地址值是无效的。

进程间的数据传递是Binder机制中的重要一环，因而有必要对它进行专门的讲解。Android系统中担负这一重任的就是Parcel。

Parcel是一种数据的载体，用于承载希望通过IBinder发送的相关信息（包括数据和对象引用）。正是基于Parcel这种跨进程传输数据的能力，进程间的IPC通信才能更加平滑可靠。Parcel的英文直译是“打包”，是对“进程间数据传递”的形象描述。上面已经说过，直接传送对象的内存地址的做法是行不通的。那么，如果把对象在进程A中占据的内存相关数据打包起来，然后寄送到进程B中，由B在自己的进程空间中“复现”这个对象，是否可行呢？

Parcel就具备这种打包和重组的能力。它提供了非常丰富的接口以方便应用程序的使用，详细说明可参见官方文档http://developer.android.com/reference/android/os/Parcel.html。下面先对这些接口进行一个分类。

1．Parcel设置相关

毋庸置疑，存入的数据越多，Parcel所占内存空间也就越大。我们可以通过以下方法来进行相关设置。

dataSize()：获取当前已经存储的数据大小。

setDataCapacity (int size)：设置Parcel的空间大小，显然存储的数据不能大于这个值。

setDataPosition (int pos)：改变Parcel中的读写位置，必须介于0和dataSize()间。

dataAvail()：当前Parcel中的可读数据大小。

dataCapacity()：当前Parcel的存储能力。

dataPosition()：数据的当前位置值，有点类似于游标。

dataSize()：当前Parcel所包含的数据大小。

2．Primitives

原始类型数据的读写操作。比如：

writeByte(byte)：写入一个byte。

readByte()：读取一个byte。

writeDouble(double)：写入一个double。

readDouble()：读取一个double。

从中也可以看到读写操作是配套的，用哪种方式写入的数据就要用相应的方式正确读取。另外，数据是按照host cpu的字节序来读写的。

3．Primitive Arrays

原始数据类型数组的读写操作通常是先写入用4个字节表示的数据大小值，接着才写入数据本身。另外，用户既可以选择将数据读入现有的数组空间中，也可以让Parcel返回一个新的数组。此类方法如下：

writeBooleanArray(boolean[])：写入布尔数组。

readBooleanArray(boolean[])：读取布尔数组。

boolean[]createBooleanArray()：读取并返回一个布尔数组。

writeByteArray(byte[])：写入字节数组。

writeByteArray(byte[], int, int)：和上面几个不同的是，这个函数最后面的两个参数分别表示数组中需要被写入的数据起点以及需要写入多少。

readByteArray(byte[])：读取字节数组。

byte[]createByteArray()：读取并返回一个数组。

…

注意

如果写入数据时系统发现已经超出了Parcel的存储能力，它会自动申请所需的内存空间，并扩展dataCapacity；而且每次写入都是从dataPosition()开始的。

4．Parcelables

遵循Parcelable协议的对象可以通过Parcel来存取，如开发人员经常用到的bundle就是继承自Parcelable的。与这类对象相关的Parcel操作包括：

writeParcelable(Parcelable, int)：将这个Parcelable类的名字和内容写入Parcel中，实际上它是通过回调此Parcelable的writeToParcel()方法来写入数据的。

readParcelable(ClassLoader)：读取并返回一个新的Parcelable对象。

writeParcelableArray(T[], int)：写入Parcelable对象数组。

readParcelableArray(ClassLoader)：读取并返回一个Parcelable对象数组。

5．Bundles

上面已提到，Bundle继承自Parcelable，是一种特殊的type-safe的容器。Bundle的最大特点就是采用键值对的方式存储数据，并在一定程度上优化了读取效率。这个类型的Parcel操作包括：

writeBundel(Bundle)：将Bundle写入parcel。

readBundle()：读取并返回一个新的Bundle对象。

readBundle(ClassLoader)：读取并返回一个新的Bundle对象，ClassLoader用于Bundle获取对应的Parcelable对象。

6．Active Objects

Parcel的另一个强大武器就是可以读写Active Objects。什么是Active Objects呢？通常我们存入Parcel的是对象的内容，而Active Objects写入的则是它们的特殊标志引用。所以在从Parcel中读取这些对象时，大家看到的并不是重新创建的对象实例，而是原来那个被写入的实例。可以猜想到，能够以这种方式传输的对象不会很多，目前主要有两类。

（1）Binder。Binder一方面是Android系统IPC通信的核心机制之一，另一方面也是一个对象。利用Parcel将Binder对象写入，读取时就能得到原始的Binder对象，或者是它的特殊代理实现（最终操作的还是原始Binder对象）。与此相关的操作包括：

```
writeStrongBinder(IBinder)
writeStrongInterface(IInterface)
readStrongBinder()
…
```

（2）FileDescriptor。FileDescriptor是Linux 中的文件描述符，可以通过Parcel的如下方法进行传递。

```
writeFileDescriptor(FileDescriptor), readFileDescriptor()
```

因为传递后的对象仍然会基于和原对象相同的文件流进行操作，因而可以认为是Active Object的一种。

7．Untyped Containers

它是用于读写标准的任意类型的java容器。包括：

```
writeArray(Object[]), readArray(ClassLoader), writeList(List), re
```

Parcel所支持的类型很多，足以满足开发者的数据传递请求。如果要给Parcel找个类比的话，它更像集装箱。理由如下：

- 货物无关性

即它并不排斥所运输的货物种类，电子产品可以，汽车也行，或者零部件也同样接受。

- 不同货物需要不同的打包和卸货方案

比如运载易碎物品和坚硬物品的装箱卸货方式就肯定会有很大不同。

- 远程运输和组装

集装箱的货物通常是要跨洋运输的，有点类似于Parcel的跨进程能力。不过集装箱运输公司本身并不负责所运送货物的后期组装。举个例子，汽车厂商需要把一辆整车先拆卸成零部件后才能进行装货运输；到达目的地后，货运公司只需要把货物完整无缺地交由接收方即可，并不负有组装成整车的义务。而Parcel则更加敬业，它会依据协议（打包和重组所用的协议必须是配套的）来为接收方提供完整还原出原始数据对象的业务。

接下来，我们看看Parcel内部是如何实现的。

应用程序可以通过Parcel.obtain()接口来获取一个Parcel对象。如下所示：

```
/*frameworks/base/core/java/android/os/Parcel.java*/
public static Parcel obtain() {
    final Parcel[] pool = sOwnedPool;/*系统预先产生了一个Parcel池
    synchronized (pool) {
       Parcel p;
       for (int i=0; i<POOL_SIZE; i++) {
           p = pool[i];
           if (p != null) {
               pool[i] = null; //引用置为空，这样下次就知道这个Par
               …
               return p;
           }
       }
    }
    return new Parcel(0); //如果Parcel池中已空，就新创建一个
}
```

新生成的Parcel有何奥妙之处，我们来看看它的构造函数：

```
private Parcel(int nativePtr) {
    …
    init(nativePtr);
```

```
    }
```

这里什么都没有做，只是调用了init()函数，注意传入的nativePtr为0：

```
    private void init(int nativePtr) {
        if (nativePtr != 0) {
            mNativePtr = nativePtr;
            mOwnsNativeParcelObject = false;
        } else { //nativePtr为0
            mNativePtr = nativeCreate(); //为本地层代码准备的指针
            mOwnsNativeParcelObject = true;
        }
    }
```

Parcel的JNI层实现在/frameworks/base/core/jni中，实际上Parcel.java只是一个简单的中介，最终所有类型的读写操作都是通过本地代码实现的：

```
/*frameworks/base/core/jni/android_os_Parcel.cpp*/
static jint android_os_Parcel_create(JNIEnv* env, jclass clazz)
{
    Parcel* parcel = new Parcel();
    return reinterpret_cast<jint>(parcel);
}
```

所以上面的mNativePtr变量实际上是本地层的一个Parcel(C++)对象。接下来的内容就围绕这个对象展开，分为以下两个关键部分。

- Parcel中如何存储数据。
- 我们选其中两个代表性的数据类型（String和Binder）来分析Parcel的处理流程，对应的接口分别是：writeString()/readString()和writeStrongBinder()/readStrongBinder()。

先来看看Parcel(cpp)类的构造过程：

```
/*frameworks/native/libs/binder/Parcel.cpp*/
Parcel::Parcel()
{
    initState();
}
void Parcel::initState()
{
```

```
    mError = NO_ERROR;
    mData = 0;
    mDataSize = 0;
    mDataCapacity = 0;
    mDataPos = 0;
    mObjects = NULL;
    mObjectsSize = 0;
    …//其他成员变量的初始化省略
}
```

Parcel对象的初始化过程只是简单地给各个变量赋了初值，并没有我们设想中的内存分配动作。这是因为Parcel遵循的是“动态扩展”的内存申请原则，只有在需要时才会申请内存以避免资源浪费。我们先来介绍上面代码段中出现的几个重要变量，因为后面的读写操作实际上就是围绕它们而实施的：

```
    status_t       mError; //错误码
    uint8_t*       mData;  //Parcel中存储的数据，注意它是一个uint8_t类
    size_t         mDataSize; //Parcel中已经存储的数据大小
    size_t         mDataCapacity; //最大存储能力
    mutable size_t      mDataPos; //数据指针
```

本小节剩余内容将结合一个范例来详细讲解writeString的实现原理，而Binder对象的读写过程因为与后续小节关系紧密，稍后将统一分析。这个范例是ServiceManagerProxy的getService()方法中对Parcel的操作（后面对ServiceManagerProxy有详细分析）。源码如下：

```
Parcel data = Parcel.obtain();
…
data.writeInterfaceToken(IServiceManager.descriptor);
data.writeString(name);
```

第一句代码用于获得一个Parcel对象，我们已经分析过——它最终是创建了一个本地的Parcel实例，并做了全面的初始化操作。

第二句中的writeInterfaceToken用于写入IBinder接口标志，所带参数是String类型的，如IServiceManager.descriptor = "android.os.IServiceManager"。

第三句通过writeString在Parcel中写入需要向ServiceManager查询的Service名称。

Parcel在整个IPC中的内部传递过程比较烦琐，特别在承载Binder数据时更是需要多次转换，因而容易让人失去方向。但不管过程如何曲折，有一点是始终不变的。那就是：

写入方和读取方所使用的协议必须是完全一致的。

正如上面所举集装箱的例子，装货和卸货的规则是成套的，不能装货时用的是对付易碎物品的方式，而卸货时又把它当成坚硬物品。

来看看写入方（ServiceManagerProxy）都“装”了些什么东西到“集装箱”中：

```
status_t Parcel::writeInterfaceToken(const String16& interface)
{
    writeInt32(IPCThreadState::self()->getStrictModePolicy() |STR
    return writeString16(interface);
}
```

这里就不深入看getStrictModePolicy()的源码实现了，而只要知道这个函数取得了一个int数值即可。因而上面的语句等价于：

```
writeInterfaceToken→writeInt32(policy value)+writeString16(interf
```

其中interface就是"android.os.IServiceManager"。

再来分别看看writeInt32和writeString16都做了哪些工作：

```
status_t Parcel::writeInt32(int32_t val)
{
    return writeAligned(val);
}
```

这个函数的实现很简单——只包含了一句代码。从函数名来判断，它是将val值按照对齐方式写入Parcel的存储空间中。换句话说，就是将数据写入mDataPos起始的mData中（当然，内部还需要判断当前的存储能力是否满足要求、是否要申请新的内存等）：

```
status_t Parcel::writeString16(const String16& str)
{
    return writeString16(str.string(), str.size());
}
```

```
status_t Parcel::writeString16(const char16_t* str, size_t len)
{
    if (str == NULL) return writeInt32 (-1); //str不为空

    status_t err = writeInt32(len); //先写入数据长度
    if (err == NO_ERROR) {
        len *= sizeof(char16_t); //长度*单位大小=占用的空间
        uint8_t* data = (uint8_t*)writeInplace(len+sizeof(char16_
        if (data) {
            memcpy(data, str, len);/*将数据复制到data所指向的位置中*/
            *reinterpret_cast<char16_t*>(data+len) = 0;
            return NO_ERROR;
        }
        err = mError;
    }
    return err;
}
```

整个writeString16的处理过程并不难理解：首先要填写数据的长度，占据4个字节；然后计算出数据所需占据的空间大小；最后才将数据复制到相应位置中——writeInplace就是用来计算复制数据的目标地址的（下面分段阅读）：

```
void* Parcel::writeInplace(size_t len)
{
    const size_t padded = PAD_SIZE(len);
```

PAD_SIZE用于计算“当以4对齐时，容纳len大小的数据需要多少空间”（注意len在传进来时进行了len *= sizeof(char16_t)），即：

```
#define PAD_SIZE(s) (((s)+3)&～3)
```

比如len=3, padded = 4

len =4, padded=4

len=5, padded =8

```
    if (mDataPos+padded < mDataPos) {
        return NULL;
    }
```

如果溢出就直接返回NULL。

下面代码段先写入尾部的填充数据（注意，数据内容本身不在writeInplace函数里复制），手法和writeAligned类似：

```
    if ((mDataPos+padded) <= mDataCapacity) {/*数据大小没有超过容量*/
restart_write:
        uint8_t* const data = mData+mDataPos;
        if (padded != len) {/*需要填充尾部的情况*/
#if BYTE_ORDER == BIG_ENDIAN /*如果是Big Endian的情况*/
          static const uint32_t mask[4] = {
             0x00000000, 0xffffff00, 0xffff0000, 0xff000000
          };
#endif
#if BYTE_ORDER == LITTLE_ENDIAN /*如果是Little Endian的情况*/
          static const uint32_t mask[4] = {
             0x00000000, 0x00ffffff, 0x0000ffff, 0x000000ff
          };
#endif
          *reinterpret_cast<uint32_t*>(data+padded-4) &= mask[pad
       }

        finishWrite(padded);/*更新mDataPos*/
        return data;
    }
    /*如果程序执行到这里，说明数据大小已经超过了Parcel的存储能力，需要扩大容
    status_t err = growData(padded);
    if (err == NO_ERROR) goto restart_write;/*重新开始业务*/
    return NULL;
}/*writeInplace结束*/
```

上面代码段的逻辑是：如果空间足够，就直接进行尾部的填充操作；否则要申请更多的存储空间（growData），然后返回restart_write继续执行。尾部需要padding多少数据是由len和padded综合决定的，如当len=5时，padded=8，这时就有3个字节是填充数据（最多不超过4）。填充数据的写法采用的是：

```
*reinterpret_cast<uint32_t*>(data+padded-4) &= mask[padded-len];
```

这里先做了uint32_t的强制转换，所以后续操作就是以4个字节为单位——这样可以一次性把3个字节的填充数据（即mask[3]=0xff000000或者0x000000ff，取决于是LITTLE_ENDIAN还是BIG_ENDIAN）都写入。

最后调用finishWrite来调整mDataPos指针，并返回data的位置以

供调用者写入真正的数据内容。

可以看出，writeInplace用于确认即将写入的数据的起始和结束位置，并做好padding工作。我们再回到之前的writeString16继续分析。因为有了需要写入的地址（即data指针），所以可以直接memcpy。如下：

```
memcpy(data, str, len);
```

最后写入字符串结束符0：

```
*reinterpret_cast<char16_t*>(data+len) = 0;
```

通过上面的分析，写入一个String(writeString16)的步骤：

- writeInt32(len)；
- memcpy；
- padding（有些情况下不需padding。而且源码实现中这一步是在memcpy之前）。

回到ServiceManagerProxy中的getService里：

```
data.writeInterfaceToken(IServiceManager.descriptor);
data.writeString(name);
```

我们把上面两个语句进行分解，就得到写入方的工作了：

```
WriteInterfaceToken=writeInt32(policy value)+writeString16(interf
writeString16(interface) = writeInt32(len)+写入数据本身+填充
```

根据上面强调的准则，读取方也必须遵循同样的数据操作顺序。

接下来我们做下验证。

读取方是Service_manager.c（分段阅读）：

```
/*frameworks/native/cmds/servicemanager/Service_manager.c*/
int svcmgr_handler(struct binder_state *bs, struct binder_txn *tx
                struct binder_io *msg, struct binder_io *reply)
{…
     uint32_t strict_policy;
```

```
…
strict_policy = bio_get_uint32(msg); //取得policy值
s = bio_get_string16(msg, &len); //取得一个String16,即上面写入的
if ((len != (sizeof(svcmgr_id) / 2)) ||
     memcmp(svcmgr_id, s, sizeof(svcmgr_id))) {/*判断Interfac
     fprintf(stderr,"invalid id %s\n", str8(s));
     return -1;
}
```

上面代码段用于判断收到的interface是否正确。其中：

```
uint16_t svcmgr_id[] = {
    'a','n','d','r','o','i','d','.','o','s','.',
    'I','S','e','r','v','i','c','e','M','a','n','a','g','e','r'
};
```

可见，和前面的"android.os.IServiceManager"是一样的：

```
switch(txn->code) {
case SVC_MGR_GET_SERVICE:
case SVC_MGR_CHECK_SERVICE:
    s = bio_get_string16(msg, &len);//获取要查询的service name
    ptr = do_find_service(bs, s, len, txn->sender_euid);
    if (!ptr)
        break;
    bio_put_ref(reply, ptr);
    return 0;
```

可以看到，ServiceManager对数据的读取过程和数据的写入过程确实完全一致。这样我们以String为例，完整地分析了Parcel对基本数据类型的读写流程。相对于基础数据类型，Binder（Active Object）的跨进程传递要复杂很多，读者在后续小节中即可看到。

6.3 Binder驱动与协议

“万丈高楼平地起”，无论多复杂的系统都是从最基础的理论一点一滴构建起来的。比如本书前面章节分析过的Android编译系统，就是从最简单的make规则不断扩展堆叠而成的。Binder作为Android中另一个庞大的体系，虽然代码量多、跨度广，但也同样需要自己的“地基”——Binder驱动。

我们知道，Android系统是基于Linux内核的，因而它所依赖的Binder驱动也必须是一个标准的Linux驱动。具体而言，Binder Driver会将自己注册成一个misc device，并向上层提供一个/dev/binder节点——值得一提的是，Binder节点并不对应真实的硬件设备。Binder驱动运行于内核态，可以提供open()，ioctl()，mmap()等常用的文件操作。

本小节将主要从用户的角度来解释Binder驱动所提供的功能以及它和用户之间的协议，并辅以一定的源码分析。在此之前，我们强烈建议读者能先学习下Linux驱动编程的一些基础知识。

Binder驱动源码在Kernel工程的drivers/staging/android目录中。

Android系统为什么把Binder注册成misc device类型的驱动呢？

这种“杂项”驱动的主设备号统一为10，次设备号则是每种设备独有的。驱动程序也可以通过设置MISC_DYNAMIC_MINOR来由系统动态分配次设备号。

Linux中的字符设备通常要经过alloc_chrdev_region()，cdev_init()等一系列操作才能在内核中注册自己。而misc类型驱动则相对简单，只需要调用misc_register()就可轻松解决。比如Binder中与驱动注册相关的代码：

```
/*drivers/staging/android/Binder.c*/
static struct miscdevice binder_miscdev = {
     .minor = MISC_DYNAMIC_MINOR, /*动态分配次设备号*/
     .name = "binder", /*驱动名称*/
     .fops = &binder_fops /*Binder驱动支持的文件操作*/
```

```
};
static int __init binder_init(void)
{    …
     ret = misc_register(&binder_miscdev); /*驱动注册*/
     …
}
```

Binder驱动还需要填写file_operations结构体。如下所示：

```
/*drivers/staging/android/Binder.c*/
static const struct file_operations binder_fops = {
     .owner = THIS_MODULE,
     .poll = binder_poll,
     .unlocked_ioctl = binder_ioctl,
     .mmap = binder_mmap,
     .open = binder_open,
     .flush = binder_flush,
     .release = binder_release,
};
```

由此可见，Binder驱动总共为上层应用提供了6个接口——其中使用最多的就是binder_ioctl，binder_mmap和binder_open。而一般文件操作需要用到的read()和write()则没有出现，这是因为它们的功能完全可以用ioctl()和mmap()来代替；而且后两者还更加灵活，稍后会做详细讲解。

另外，Binder所使用的设备驱动入口函数并不是module_init()，而是：

```
device_initcall(binder_init);
```

这样做的目的可能是Android系统并不想支持动态编译的驱动模块。如果读者有动态编译需求的话，可以将其改成module_init和module_exit。

6.3.1　打开Binder驱动——binder_open

上层进程在访问Binder驱动时，首先就需要打开/dev/binder节点，这个操作最终的实现是在binder_open()中。如下所示（分段阅读）：

```
/*如果没有特别说明，以下的函数都在Binder.c中*/
```

```
static int binder_open(struct inode *nodp, struct file *filp)
{
     struct binder_proc *proc;
     …
     proc = kzalloc(sizeof(*proc), GFP_KERNEL);/*分配空间*/
     if (proc == NULL)
          return -ENOMEM;
```

Binder驱动会在/proc系统目录下生成各种管理信息（比如/proc/binder/proc，/proc/binder/state，/proc/binder/stats等）。上面代码段中的binder_proc就是管理数据的记录体（每个进程都有独立记录）。

接下来对这个新生成的proc对象进行各种初始化操作：

```
get_task_struct(current);
proc->tsk = current;
INIT_LIST_HEAD(&proc->todo); //todo链表
init_waitqueue_head(&proc->wait); //wait链表
proc->default_priority = task_nice(current);
```

完成proc的初始化后，接下来应该做什么呢？没错，将它加入Binder的全局管理中。以下代码段涉及了资源互斥，因而需要使用保护机制：

```
     binder_lock(__func__);/获取锁
     binder_stats_created(BINDER_STAT_PROC); /*binder_stats是binde
     hlist_add_head(&proc->proc_node, &binder_procs); /*将proc加入
                                                          列头部*/
     proc->pid = current->group_leader->pid;/*进程pid*/
     INIT_LIST_HEAD(&proc->delivered_death);
     filp->private_data = proc; /*将这个proc与filp关联起来，这样下次通
                              proc了*/
     binder_unlock(__func__); //解除锁
     …
     return 0;
}/*binder_open结束*/
```

到目前为止，Binder驱动已经为用户创建了一个它自己的binder_proc实体，之后用户对Binder设备的操作将以这个对象为基础。

6.3.2 binder_mmap

在操作系统基础章节曾经讲解过mmap()这个系统调用的使用方法。对于Binder驱动来说，上层用户调用的mmap()最终就对应了binder_mmap()。

先来思考一个问题，Binder中采用mmap的目的是什么呢？我们知道，mmap()可以把设备指定的内存块直接映射到应用程序的内存空间中。但Binder本身并不是一个硬件设备，而只是基于内存的“伪硬件”，那么它又映射了什么内存块到应用程序中呢？

假设有两个进程A和B，其中进程B通过open()和mmap()后与Binder驱动建立了联系，如图6-13所示。

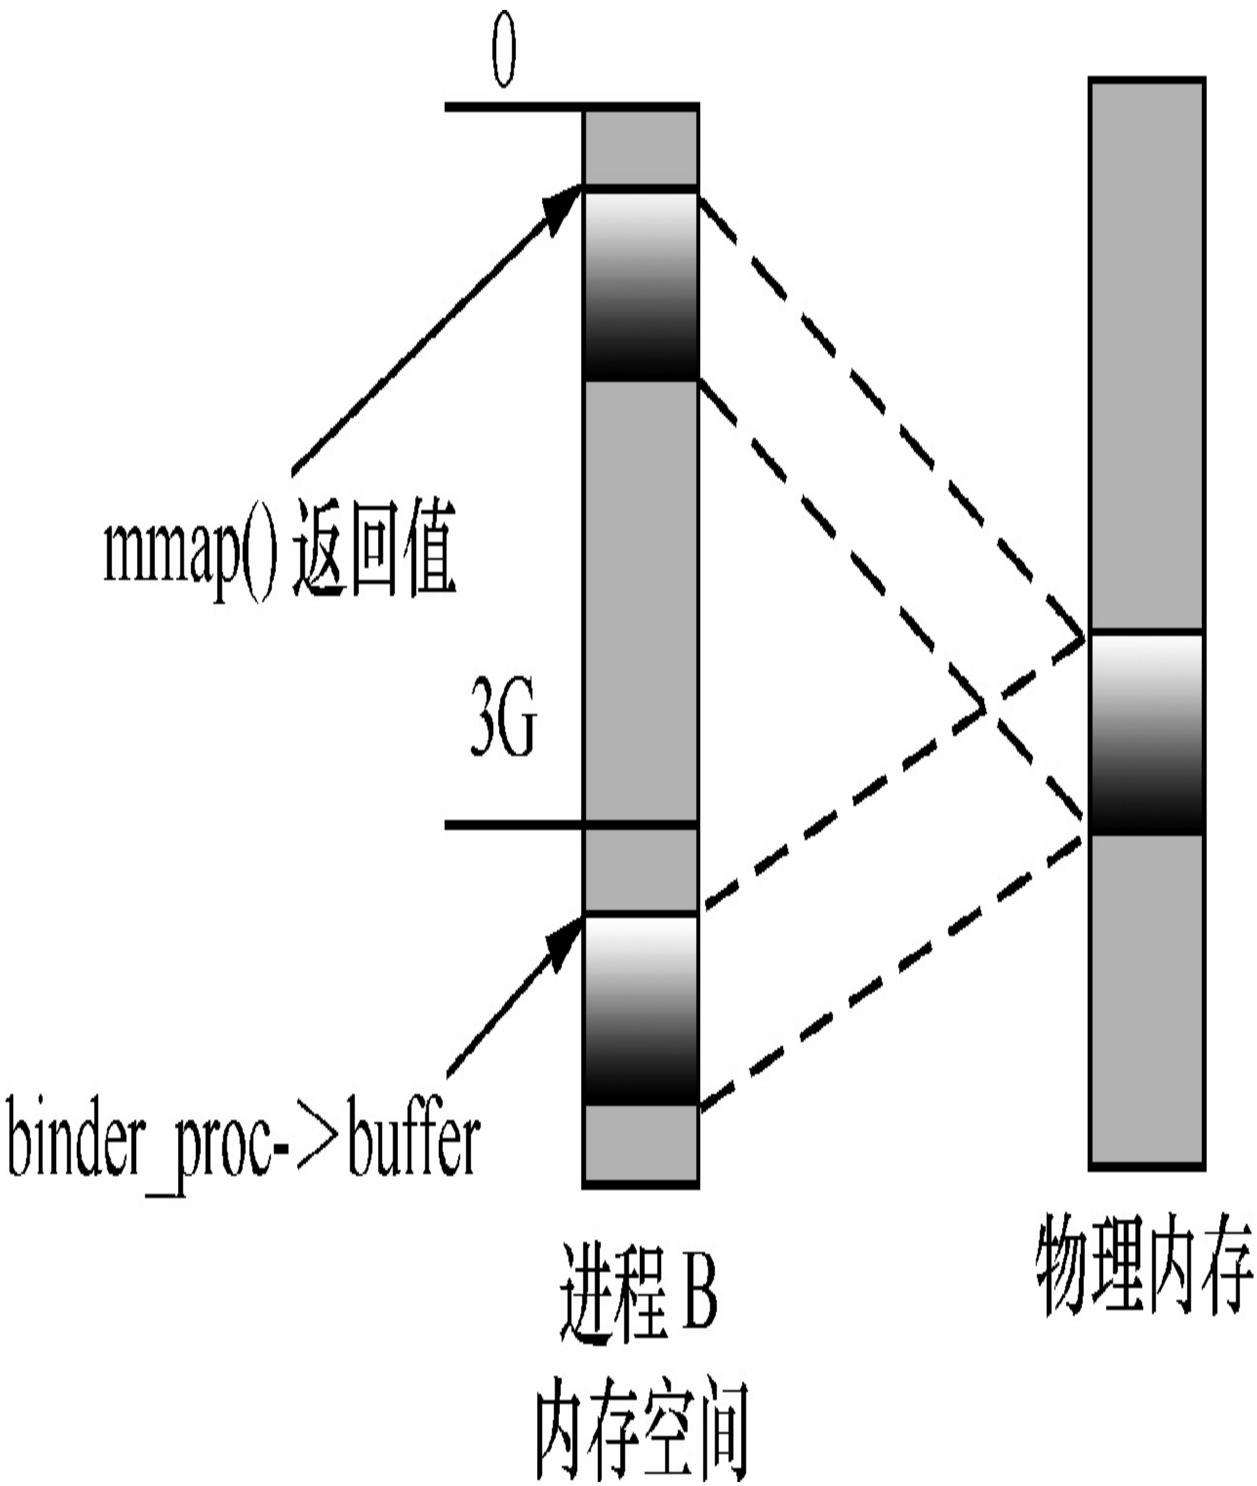

▲图6-13　进程B执行mmap()后

从图中可以看到。

- 对于应用程序而言，它通过mmap()返回值得到一个内存地址（当然这是虚拟地址），这个地址通过虚拟内存转换（分段、分页）后最终将指向物理内存的某个位置。
- 对于Binder驱动而言，它也有一个指针（binder_proc->buffer，接下来的代码中会介绍）指向某个虚拟内存地址。而经过虚拟内存转换后，它和应用程序中指向的物理内存处于同一个位置。

这时Binder和应用程序就拥有了若干共用的物理内存块。换句话说，它们对各自内存地址的操作，实际上是在同一块内存中执行的。那么，这么做有什么实际意义呢？

别着急，我们再把进程A加进来，看看情况又有哪些变化，如图6-14所示。

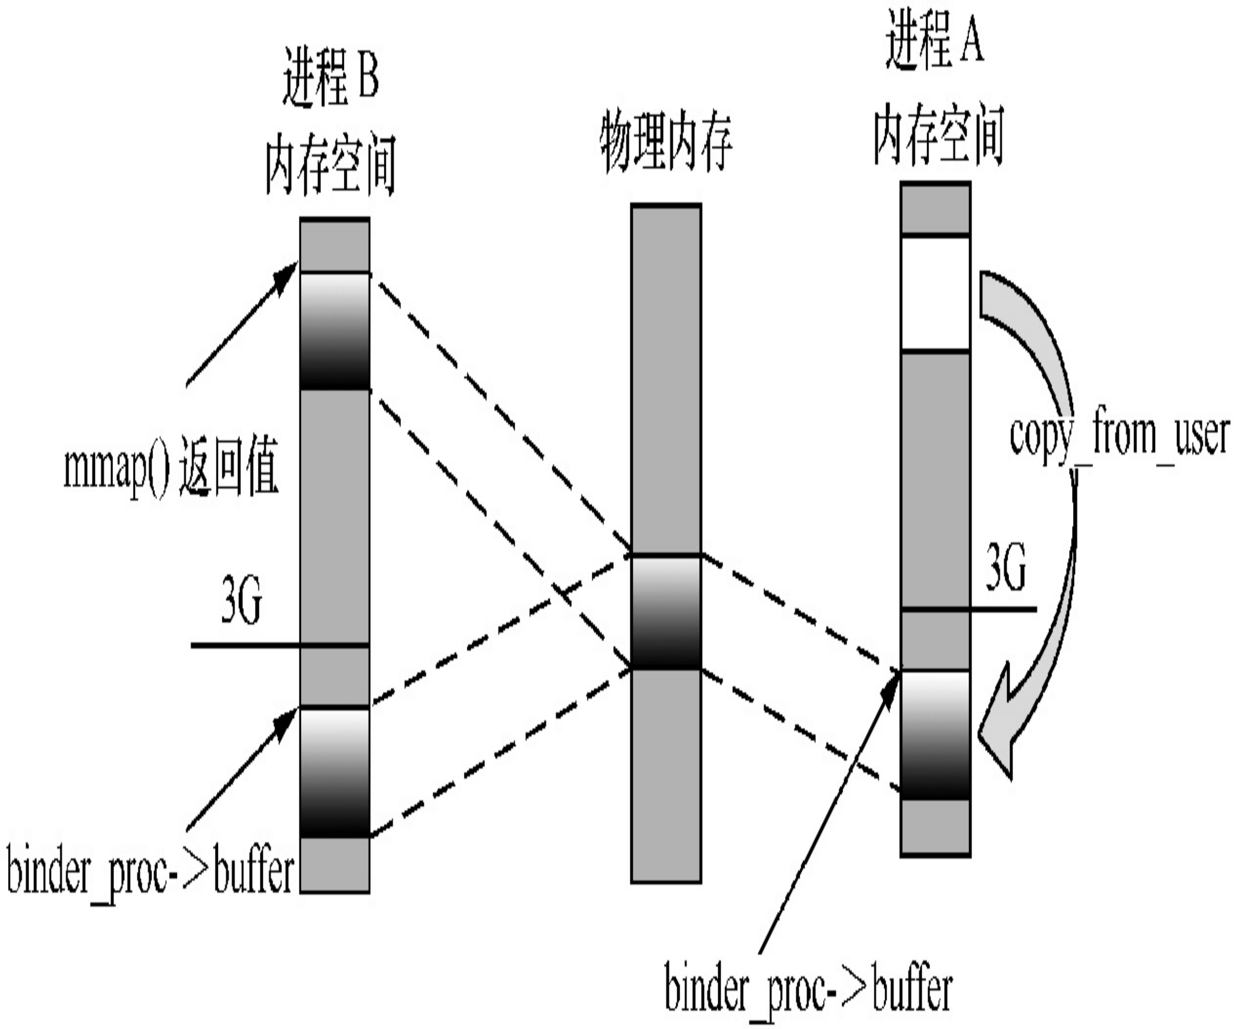

▲图6-14　进程A复制数据到进程B中

看看图中都发生了什么。左半部分没有任何变化，即进程B和Binder共用若干物理内存。右半部分Binder驱动通过copy_from_user()，把进程A中的某段数据复制到其binder_proc->buffer所指向的内存空间中。这时候我们惊喜地发现，因为binder_proc->buffer在物理内存中的位置和进程B是共享的，因而进程B可以直接访问到这段数据。也就是说，Binder驱动只用了一次复制，就实现了进程A和B间的数据共享。

有了初步的认识，我们再来分析源码就容易多了（函数很长，分段阅读）：

```
static int binder_mmap(struct file *filp, struct vm_area_struct *
{
     int ret;
     struct vm_struct *area;
     struct binder_proc *proc = filp->private_data;/*取出这一进程对
     const char *failure_string;
     struct binder_buffer *buffer;
```

先来解释几个重要的变量。

- vm_area_strut　*vma:

描述了一块供应用程序使用的虚拟内存，其中vma->vm_start和vma->vm_end分别是这块连续的虚拟内存的起止点。

- vm_struct　*area:

上面的vma是应用程序中对虚拟内存的描述，相应的area变量就是Binder驱动中对虚拟内存的描述。

- binder_proc　*proc:

这个变量在上一小节binder_open中已经碰到过。它是Binder驱动为应用进程分配的一个数据结构，用于存储和该进程有关的所有信息，如内存分配、线程管理等。

在做实际的工作前，Binder驱动会判断应用程序申请的内存大小是

否合理——它最多只支持4MB空间的mmap操作。如下：

```
if ((vma->vm_end - vma->vm_start) >SZ_4M)
     vma->vm_end = vma->vm_start + SZ_4M;
```

可以看到，当应用程序申请的内存大小超过4MB时，并没有直接退出或报异常，而是只满足用户刚好4MB的请求：

```
…
if (vma->vm_flags & FORBIDDEN_MMAP_FLAGS) {/*禁止MMAP标志*/
     ret = -EPERM;
     failure_string = "bad vm_flags";
     goto err_bad_arg;
}
vma->vm_flags = (vma->vm_flags | VM_DONTCOPY) & ~VM_MAYWRITE;
```

判断vma中的标志是否禁止了mmap，并加入新的标志：

```
mutex_lock(&binder_mmap_lock);
if (proc->buffer) {/*是否已经做过映射*/
     ret = -EBUSY;
     failure_string = "already mapped";
     goto err_already_mapped;
}
```

这里的proc->buffer用于存储最终的mmap结果（属于Binder的那个虚拟内存），因而如果不为空，说明之前已经执行过mmap操作。这种情况下Binder会判定为错误，并直接跳转到错误处理部分：

```
area = get_vm_area(vma->vm_end - vma->vm_start, VM_IOREMAP);
if (area == NULL) {
     ret = -ENOMEM;
     failure_string = "get_vm_area";
     goto err_get_vm_area_failed;
}
```

上面的get_vm_area()用于为Binder驱动获取一段可用的虚拟内存空间。也就是说，这时候还没有分配实际的物理内存：

```
proc->buffer = area->addr;/*映射后的地址*/
proc->user_buffer_offset = vma->vm_start - (uintptr_t)proc->buffe
mutex_unlock(&binder_mmap_lock);
```

将proc中的buffer指针指向这块虚拟内存起始地址，并计算出它和

应用程序中相关联的虚拟内存地址（即vma->vm_start）的偏移量：

```
…
proc->pages = kzalloc(sizeof(proc->pages[0]) * ((vma->vm_end - vm
if (proc->pages == NULL) {
     ret = -ENOMEM;
     failure_string = "alloc page array";
     goto err_alloc_pages_failed;
}
```

需要注意的是，上面的kzalloc只是分配了pages数组的空间。这个变量的声明如下：

```
struct page **pages;
```

它是一个二维指针，从名称上看是用于管理物理页面的，也就是用于指示Binder申请的物理页面的状态：

```
proc->buffer_size = vma->vm_end - vma->vm_start;
vma->vm_ops = &binder_vm_ops;
vma->vm_private_data = proc;
```

计算虚拟块大小等：

```
if (binder_update_page_range(proc, 1, proc->buffer, proc->buffer
     ret = -ENOMEM;
     failure_string = "alloc small buf";
     goto err_alloc_small_buf_failed;
}
```

上面的binder_update_page_range开始真正地申请物理页面了。下面解释下这个函数的各个参数：

```
binder_update_page_range(struct binder_proc *proc, int allocate,
                        void *start, void *end,
                        struct vm_area_struct *vma);
```

proc：申请内存的进程所持有的binder_proc对象。

allocate：是申请还是释放。1表示申请，0表示释放。

start：Binder中虚拟内存起点（页表映射当然是从虚拟内存到物理内存）。

end：Binder中虚拟内存的终点。

vma：应用程序中虚拟内存段的描述。

对照上面的函数传参会发现，在mmap中Binder驱动实际上只为进程分配了一页物理内存。虽然它最大支持4MB空间的mmap，但因为这时候还没有数据传输，显然没有必要一下子分配这么大的空间。而且试想一下，如果每个进程都要一次性分配4MB，那么25个进程就需要消耗100MB以上的内存，这对于一般的嵌入式设备来说是不现实的。

成功分配了一页物理内存后，我们还需要将这一页内存与应用程序的虚拟内存联系起来，以真正实现共享。有兴趣的读者可以再分析下binder_update_page_range的实现：

```
     buffer = proc->buffer;
     INIT_LIST_HEAD(&proc->buffers);
     list_add(&buffer->entry, &proc->buffers);
     buffer->free = 1; //此内存可用
     binder_insert_free_buffer(proc, buffer);
     proc->free_async_space = proc->buffer_size / 2;
     barrier();
     proc->files = get_files_struct(current);
     proc->vma = vma;
     return 0;

err_alloc_small_buf_failed:
     kfree(proc->pages);
     proc->pages = NULL;
err_alloc_pages_failed:
     vfree(proc->buffer);
     proc->buffer = NULL;
err_get_vm_area_failed:
err_already_mapped:
err_bad_arg:
     printk(KERN_ERR "binder_mmap: %d %lx-%lx %s failed %d\n",
            proc->pid, vma->vm_start, vma->vm_end, failure_string
     return ret;
}/*binder_mmap结束*/
```

上面的代码段对分配到的内存空间进行管理，主要工作是将其加入相应的链表中。在binder_proc中，管理着3条链表，分别是：

- list_head buffers;

所有内存块都需要在这里备案。

- rb_root free_buffers;

所有可用的空闲内存。

- rb_root allocated_buffers。

所有已经被分配了的内存。

Binder驱动中最复杂的部分就是对内存的管理，大家在后面还会不断遇到类似场景。

6.3.3 binder_ioctl

这是Binder接口函数中工作量最大的一个，它承担了Binder驱动的大部分业务。前面说过，Binder并不提供read()和write()等常规文件操作，因为binder_ioctl就可以完全替代它们。

先来看看binder_ioctl提供了哪些命令，如表6-1所示。

表6-1 binder_ioctl支持的命令

命　　令	说　　明
BINDER_WRITE_READ	读写操作，可以用此命令向Binder读取或写入数据
BINDER_SET_MAX_THREADS	设置支持的最大线程数。因为客户端可以并发向服务器端发送请求，如果Binder驱动发现当前的线程数量已经超过设定值，就会告知Binder Server停止启动新的线程

BINDER_SET_CONTEXT_MGR	Service Manager专用，将自己设置为“Binder大管家”。系统中只能有一个SM存在
BINDER_THREAD_EXIT	通知Binder线程退出。每个线程在退出时都应该告知Binder驱动，这样才能释放相关资源；否则可能会造成内存泄露
BINDER_VERSION	获取Binder版本号

其中BINDER_WRITE_READ这个命令是重点，又分为若干子命令，如表6-2所示。

表6-2　BINDER_WRITE_READ中支持的子命令

命　　令	说　　明
BC_INCREFS BC_ACQUIRE BC_RELEASE BC_DECREFS	这一组命令用于操作引用计数 参考下面的源码分析
BC_INCREFS_DONE BC_ACQUIRE_DONE	和上面的命令有关系，当 BC_INCREFS和BC_ACQUIRI 发送
BC_ATTEMPT_ACQUIRE BC_ACQUIRE_RESULT	目前版本中还没有实现，会直 EINVAL的错误码

BC_FREE_BUFFER	用于Binder的buffer管理
BC_TRANSACTION	
BC_REPLY	这是BINDER_WRITE_READ 的两个命令，Binder机制中客 器的交互基本上是靠它们完成 面会重点介绍其源码实现

BC_REGISTER_LOOPER
BC_ENTER_LOOPER
BC_EXIT_LOOPER
	用于设置binder looper的状态，
	考下一小节ServiceManager例
	述。当前版本中looper共有如
	态:
	`enum {`
	
	`BINDER_LOOPER_STATE_REGISTE`
	`0x01,`
	
	`BINDER_LOOPER_STATE_ENTERED`
	`0x02,`
	
	`BINDER_LOOPER_STATE_EXITED`
	`0x04,`
	
	`BINDER_LOOPER_STATE_INVALID`
	`0x08,`
	
	`BINDER_LOOPER_STATE_WAITING`
	`0x10,`
	
	`BINDER_LOOPER_STATE_NEED_RE`
	`0x20`
	`};`
	左边的三个命令分别对应上面
	型中的状态1，2，3。要特别
	统意义的状态不同，这里的状
	以叠加的。比如对于

	BC_ENTER_LOOPER的处理，语句是：thread->looper |= BINDER_LOOPER_STATE_E
BC_REQUEST_DEATH_NOTIFICATION BC_CLEAR_DEATH_NOTIFICATION	这组命令将通知目标对象执行操作，以及清除DEATH NOTIFICATION。显然后者必者成功的基础上才有意义
BC_DEAD_BINDER_DONE	和上面命令是相关联的

本小节中我们先不深入分析源码，因为缺乏具体情景的分析会让大家感觉很枯燥，不容易“理解吸收”。后续解析Binder Client如何获取ServiceManager（Binder Server）提供的服务时，再结合代码进行详细讨论。

最后来做一下小结：Binder驱动并没有脱离Linux的典型驱动模型，提供了多个文件操作接口。其中binder_ioctl实现了应用进程与Binder驱动之间的命令交互，可以说承载了Binder驱动中的大部分业务，因而是学习的重中之重。在本小节的讲解中，我们只列出了ioctl所支持的命令种类和含义，并对其中的BINDER_WRITE_READ进行了初步分析。这将为接下来大家分析SM及Binder Client的实现原理打下一定的基础。

6.4 “DNS”服务器——ServiceManager(Binder Server)

通过上一小节的学习，相信大家对Binder驱动已经有了一定的认识。

ServiceManager（以下简称SM）的功能可以类比为互联网中的“DNS”服务器，“IP地址”为0。另外，和DNS本身也是服务器一样，SM也是一个标准的Binder Server。Binder驱动中提供了专门为SM服务的相关命令，接下来将在这些基础上进一步分析SM的更多实现细节。

6.4.1 ServiceManager的启动

既然是DNS，那么在用户可以浏览网页前就必须就位。SM也是同样的道理，它要保证在有人使用Binder机制前就处于正常的工作状态。那么，具体来说它是什么时候运行起来的呢？

我们很自然地会想到应该是在init程序解析init.rc时启动的。事实的确如此。如下所示：

```
/*init.rc*/
service servicemanager /system/bin/servicemanager
    class core
    user system
    group system
    critical
    onrestart restart zygote
    onrestart restart media
    onrestart restart surfaceflinger
    onrestart restart drm
```

关于init.rc的用法，请读者参考本书系统启动章节。从上面代码段的描述可以看到，一旦servicemanager发生问题后重启，其他系统服务zygote，media，surfaceflinger和drm也会被重新加载。

这个servicemanager是用C/C++编写的，源码路径在工程的/frameworks/native/cmds/ servicemanager目录中，可以先来看看它的make文件：

```
LOCAL_PATH:= $(call my-dir)
…
include $(CLEAR_VARS)
LOCAL_SHARED_LIBRARIES := liblog
LOCAL_SRC_FILES := service_manager.c binder.c
LOCAL_MODULE := servicemanager /*生成的可执行文件名为servicemanager*/
include $(BUILD_EXECUTABLE)/*编译可执行文件*/
```

要特别提醒的是，servicemanager所对应的c文件是service_manager.c和binder.c。源码工程中还有其他诸如ServiceManager.cpp的文件存在，但并不属于SM程序。

SM本身的代码并不多，主要的文件只有上面makefile中描述的两个。但是它完整地描述了上层应用通过Binder驱动来构建一个Binder Server的过程，这也是我们下一小节所要分析的重点。

6.4.2　ServiceManager的构建

DNS虽然特殊，本质上却也是一个网络服务器；与此类似，SM自身也同样是Binder Server（在Android系统中，Binder Server的另一个常见称谓是“×× Service”，如Media Service）。

先来看看SM启动后都做了哪些工作：

```
/*frameworks/native/cmds/servicemanager/Service_manager.c*/
int main(int argc, char **argv)
{
    struct binder_state *bs;
    void *svcmgr = BINDER_SERVICE_MANAGER;
    bs = binder_open(128*1024);
    if (binder_become_context_manager(bs)) { /*将自己设置为Binder“大
                  系统只允许一个ServiceManager存在，因而如果后面还有人调
        ALOGE("canno t become context manager (%s)\n", strerror(e
        return -1;
    }
    svcmgr_handle = svcmgr;
    binder_loop(bs, svcmgr_handler); //进入循环，等待客户的请求
    return 0;
}
```

首先给变量svcmgr赋初值，宏的定义如下：

```
#define BINDER_SERVICE_MANAGER((void*) 0)
```

接着调用binder_open打开Binder设备。这个函数里面还有不少其他工作，稍后再专门介绍。

所以，main函数里主要做了以下几件事：

- 打开Binder设备，做好初始化；
- 将自己设置为Binder大管家；
- 进入主循环。

那么，具体来说需要做哪些初始化呢？

```
/*frameworks/native/cmds/servicemanager/Binder.c */
struct binder_state *binder_open(unsigned mapsize)
{
    struct binder_state *bs; /*这个结构体记录了SM中有关于Binder的所有信
                              如fd、map的大小等*/
    bs = malloc(sizeof(*bs));
    …
    bs->fd = open("/dev/binder", O_RDWR); //打开Binder驱动节点
    …
    bs->mapsize = mapsize; //mapsize是SM自己设的，为128*1024，即128K
    bs->mapped = mmap(NULL, mapsize, PROT_READ, MAP_PRIVATE, bs->
    …
    return bs;
fail_map:
    close(bs->fd); //关闭file
fail_open:
    free(bs);
    return 0;
}
```

关于mmap的用法，在操作系统章节以及前面的Binder驱动中都有过详细讲解，如果读者还不是很清楚，请复习查阅。根据上面代码段中的参数设置可知：

- 由Binder驱动决定被映射到进程空间中的内存起始地址；
- 映射区块大小为128KB；
- 映射区只读；
- 映射区的改变是私有的，不需要保存文件；
- 从文件的起始地址开始映射。

下面来看看main函数中的第二步操作，即将servicemanager注册成Binder机制的“大管家”：

```
int binder_become_context_manager(struct binder_state *bs)
{
    return ioctl(bs->fd, BINDER_SET_CONTEXT_MGR, 0);
}
```

如我们在驱动小节所讲解的，只要向Binder Driver发送BINDER_SET_CONTEXT_MGR的ioctl命令即可。因为servicemanager启动得很早，能保证它是系统中第一个向Binder驱动注册成“管家”的程序。

所有准备工作已经就绪，SM可以开始等待客户端的请求——这一部分工作才是SM的重点和难点。我们先从binder_loop()入手来看看SM是如何处理请求的（分段阅读）：

```
void binder_loop(struct binder_state *bs, binder_handler func)
{
    int res;
    struct binder_write_read bwr; /*这是执行BINDER_WRITE_READ命令所
    unsigned readbuf[32];/*一次读取容量*/
```

在Binder Server进入循环前，它要先告知Binder驱动这一状态变化。下面这段代码就是为了完成这项工作：

```
    bwr.write_size = 0;//这里只是先初始化为0，下面还会再赋值
    bwr.write_consumed = 0;
    bwr.write_buffer = 0;
    readbuf[0] = BC_ENTER_LOOPER;/*命令*/
    binder_write(bs, readbuf, sizeof(unsigned)); //这个函数很简单，
```

然后SM就进入了循环。大家可以先想一想，循环体中需要做些什么。

没错，和典型的基于事件驱动的程序循环框架类似。

- 从消息队列中读取消息。
- 如果消息是“退出命令”，则马上结束循环；如果消息为空，则继续读取或者等待一段时间后再读取；如果消息不为空且不是退出命令，则根据具体情况进行处理。

- 如此循环往复直到退出。

不过SM中没有消息队列，它的“消息”（或称“命令”）是从Binder驱动那里获得的：

```
    for (;;) {
        bwr.read_size = sizeof(readbuf);/*readbuf的大小为32个unsigr
        bwr.read_consumed = 0;
        bwr.read_buffer = (unsigned) readbuf;/*读取的消息存储到readb
        res = ioctl(bs->fd, BINDER_WRITE_READ, &bwr); //读取“消息”
        …
        res = binder_parse(bs, 0, readbuf, bwr.read_consumed, fun
        if (res == 0) {
            ALOGE("binder_loop: unexpected reply?!\n");
            break;
        }
        if (res < 0) {
            ALOGE("binder_loop: io error %d %s\n", res, strerror(
            break;
        }
    }
}/*binder_loop结束*/
```

由此可见，SM遵循以下几个步骤。

- 从Binder驱动读取消息

通过发送BINDER_WRITE_READ命令实现——这个命令既可读取也可写入，具体要看bwr.write_size和bwr.read_size。因为这里write_size的初始化值为0，而read_size为sizeof(readbuf)，所以Binder驱动只执行读取操作。

- 处理消息

调用binder_parse来解析消息。

- 不断循环，而且永远不会主动退出（除非出现致命错误）

再来看看binder_parse的处理（分段阅读）：

```
int binder_parse(struct binder_state *bs, struct binder_io *bio,
              uint32_t *ptr, uint32_t size, binder_handler func)
```

```
                    /*func函数在SM中对应svcmgr_handler()*/
{
    int r = 1;
    uint32_t *end = ptr + (size / 4); //一个uint32_t占用4个字节

    while (ptr < end) {
        uint32_t cmd = *ptr++;/*一个cmd占用一个uint32_t，因而取得cmd后
        …
```

函数首先计算数据的终点（end），然后进入while循环（直到所有数据处理完成）。数据的头部是cmd，代表了程序接下来要处理的具体命令——其中BR_NOOP，BR_TRANSACTION_COMPLETE以及操作引用计数的一组命令（BR_INCREFS等）并不需要特别处理。如下所示：

```
        switch(cmd) {
        case BR_NOOP:
            break;
        case BR_TRANSACTION_COMPLETE:
            break;
        case BR_INCREFS:
        case BR_ACQUIRE:
        case BR_RELEASE:
        case BR_DECREFS:
          …
            ptr += 2;
            break;
        case BR_TRANSACTION: {/*下面会详细分析这个命令*/
            struct binder_txn *txn = (void *) ptr;/*binder_txn和B
            transaction_data是类似的*/
            …
            binder_dump_txn(txn); //dump追踪
            if (func) { //这个函数是svcmgr_handler()*/
                unsigned rdata[256/4];
                struct binder_io msg;
                struct binder_io reply;
                int res;
                bio_init(&reply, rdata, sizeof(rdata), 4);
                bio_init_from_txn(&msg, txn);
                res = func(bs, txn, &msg, &reply);/*具体处理消息*/
                binder_send_reply(bs, &reply, txn->data, res);/*回
            }
            ptr += sizeof(*txn) / sizeof(uint32_t);/*处理完成，跳过
            break;
        }
       case BR_REPLY: {
            struct binder_txn *txn = (void*) ptr;/*REPLY和TRANSAC
```

```
        “tx”经常被用来表示“收”和“发”两种双向操作*/
        …
        binder_dump_txn(txn);//追踪调试
        if (bio) {
            bio_init_from_txn(bio, txn);
            bio = 0;
        } else {
                /* todo FREE BUFFER */
        }
        ptr += (sizeof(*txn) / sizeof(uint32_t)); //跳过了这个命
        r = 0;
        break;
    }
    …
}/*binder_parse结束*/
```

和在Binder驱动中的情况一样，我们要重点关注下BR_TRANSACTION和BR_REPLY（特别是前者）。

1．BR_TRANSACTION

对BR_TRANSACTION命令的处理主要由func来完成，然后将结果返回给Binder驱动。

为了保持连贯性，我们紧接着来看看func函数的实现，再分析BR_REPLY的处理。因为ServiceManager是为了完成“Binder Server Name”（域名）和“Server Handle”（IP地址）间对应关系的查询而存在的，所以可推测出它提供的服务应该至少包括以下几种。

- 注册

当一个Binder Server创建后，它们要将自己的[名称，Binder句柄]对应关系告知SM进行备案。

- 查询

即应用程序可以向SM发起查询请求，以获知某个Binder Server所对应的句柄。

- 其他信息查询

比如SM版本号、当前的状态等。当然，这一部分不是必需的，可以不实现。

函数很长（分段阅读）：

```
int svcmgr_handler(struct binder_state *bs, struct binder_txn *tx
                struct binder_io *msg, struct binder_io *reply)
{
    struct svcinfo *si;
    uint16_t *s;
    unsigned len;
    void *ptr;
    uint32_t strict_policy;
    int allow_isolated;

    if (txn->target != svcmgr_handle) //SM的handle为0
        return -1;

    strict_policy = bio_get_uint32(msg);
    s = bio_get_string16(msg, &len);
    if ((len != (sizeof(svcmgr_id) / 2)) ||
        memcmp(svcmgr_id, s, sizeof(svcmgr_id))) {
        fprintf(stderr,"invalid id %s\n", str8(s));
        return -1;
    }
```

bio_XX系列函数为取出各种类型的数据提供了便利，之后就要根据具体的命令来进行处理。

- SVC_MGR_GET_SERVICE。
- SVC_MGR_CHECK_SERVICE：

上面两个命令是一样的，都是根据Server名称查找到它的handle值。

- SVC_MGR_ADD_SERVICE：

用于注册一个Binder Server。

- SVC_MGR_LIST_SERVICES：

获取列表中的对应Server。

如下所示：

```
switch(txn->code) {
case SVC_MGR_GET_SERVICE:
case SVC_MGR_CHECK_SERVICE:
   s = bio_get_string16(msg, &len);
   ptr = do_find_service(bs, s, len, txn->sender_euid);/*这个函
                                          护有一个全局的svclist变量，用于保存所
                                        整个查找过程没有涉及很复杂的逻辑，因而我们
   if (!ptr)
       break;
   bio_put_ref(reply, ptr);/*保存查询结果，以返回给客户端*/
   return 0;
```

查询的过程很简单，主要是调用do_find_service来遍历内部列表，并返回目标Server对象，最后将结果存入reply中：

```
case SVC_MGR_ADD_SERVICE:
   s = bio_get_string16(msg, &len);
   ptr = bio_get_ref(msg);
   allow_isolated = bio_get_uint32(msg) ? 1 : 0;
   if (do_add_service(bs, s, len, ptr, txn->sender_euid, allo

       return -1;
   break;
```

注册Binder Server的过程也类似：首先要在SM所维护的数据列表中查找是否已经有对应的节点存在；否则需要创建一个新的节点来记录这个Server。然后将这个Server中所带的信息写入列表的相应节点中，以备后期查询：

```
case SVC_MGR_LIST_SERVICES: {
    unsigned n = bio_get_uint32(msg);
    si = svclist;//所有Server信息都保存于此
    while ((n-- > 0) && si)
       si = si->next;
    if (si) {
        bio_put_string16(reply, si->name);//保存结果
       return 0;
    }
    return -1;
}
default:
    ALOGE("unknown code %d\n", txn->code);
    return -1;
```

```
}
…
}
```

Service Manager的功能架构比较简洁——其内部维护着一个svclist列表，用于存储所有Server相关信息（以svcinfo为数据结构），查询和注册都是基于这个表展开的。

函数svcmgr_handler处理完成后，binder_parse会进一步通过binder_send_reply来将执行结果回复给底层Binder驱动，进而传递给客户端。然后binder_parse会进入下一轮的while循环，直到ptr < end为fasle——此时说明Service Manager上一次从驱动层读取的消息都已处理完成，因而它还会继续向Binder Driver发送BINDER_WRITE_READ以查询有没有新的消息。如果有的话就处理；否则会进入休眠等待。

2．BR_REPLY

这样我们就完成了对BR_TRANSACTION命令处理过程的分析。现在回到binder_parse函数，接着往下看BR_REPLY（还记得吗？我们之前是在binder_parse中一直往下追踪的）的处理，其实都大同小异，所以下面只截取部分关键代码：

```
case BR_REPLY: {
          struct binder_txn *txn = (void*) ptr;
          …
          if (bio) {
             bio_init_from_txn(bio, txn);
             bio = 0;
          } else {
                 /* todo FREE BUFFER */
          }
          ptr += (sizeof(*txn) / sizeof(uint32_t));
          r = 0;
          break;
      }
```

可以看到，SM对BR_REPLY并没有实质性的动作。这也是正常的，因为SM是为别人服务的，并没有向其他Binder Server主动发起请求的情况。总的来说，SM的逻辑比较清晰，功能也单一，没有太多难以理解的地方。而Java层的应用程序在使用Binder驱动时就没有这么直接，大家在后面的几个小节中就可以体会到了。

6.4.3　获取ServiceManager服务——设计思考

经过前两个小节的努力，ServiceManager已经成功地运转起来了。那么，我们该如何获取它所提供的服务呢？准确地说，获取SM服务是Binder Client（即后一个小节的分析范畴）需要做的工作之一。不过SM是Binder Server中的典型范例，以此为切入点相信可以让读者更好地理解Binder庞大的“上层建筑”，因而我们选择在SM小节中对Binder Client进行初步的解析。

不少读者会有疑问，既然SM是基于native代码实现的，那么获取SM服务是不是也必须用native语言来实现呢？答案就是——它们之间并没有必然的联系。换句话说，所有Binder Client或者Binder Server都是围绕Binder驱动展开的，因而只要能正常使用Binder驱动，采用哪种编程语言都是可以的。

本小节主要讲述Java层的应用程序如何使用SM服务。

如果读者之前分析过Java层Binder机制的源码，相信会发现这其中涉及一大堆拗口的术语，如代理（proxy）、本地（native）、接口（interface）等；以及一系列让人无比头疼的BpBinder、BnBinder、Iiterface、Ibinder、asInterface、asBinder、transaction等类和方法。从项目经验来看，正是这些源源不断涌现出的费解的实现方式阻碍了很多人理解和学习Binder的脚步。

一些参考资料会直接列出这些类之间的继承关系，从而组成一张庞大的类图。但其实这样的学习方式效果并不好，很多初学者看了之后更加迷糊。所以本书希望找到一种更好的方法，以帮助大家真正地理解Binder。

总结市面上的一些教材，我们认为可能犯了“本末倒置”的错误——即先给大家看了答案，然后才来讲解问题本身。好比是先看到了答案——10，然后再来推断为什么是10（甚至可以说是赶着“思路”往10这个方向“凑”）。但这无疑是没有结果的，因为5+5=10，但4+6也同样等于10。因而可想而知，这种方法的最好结果顶多是个别聪明人真的反推出了10=5+5，但这并不一定是最好的答案。

反观Binder的学习也是一样，我们不应该一开始就看到proxy，native这些东西，因为它们是解决“如何提供Binder Server服务”这

个问题答案的一部分。正确的方法，或许应该从Binder和SM设计的角度出发，去思考如果要提供SM的某个功能，则应该怎么做。我相信Binder的创始人也是经历了这样的一段反复思索论证过程后才最终确定下来最适合Binder机制的实现方式的。

接下来我们就根据前面几个小节学习的知识来充分思考下：如果要访问SM(Binder Server)的服务，流程应该是怎么样的呢？

无非就是以下几步：

- 打开Binder设备；
- 执行mmap；
- 通过Binder驱动向SM发送请求（SM的handle为0）；
- 获得结果。

不要怀疑，核心工作确实只有这些。不过一些具体细节还需要再商榷，比如：

- 向SM发起请求的Binder Client可能是Android的APK应用程序，所以SM必须要提供Java层接口。
- 如果每个Binder Client都要亲力亲为地执行以上几个步骤来获取SM服务，那么可想而知会浪费不少时间。Android系统当然也想到了这一点，所以它会提供更好的封装来使整个SM调用过程更精简实用。
- 如果应用程序代码中每次使用SM服务（或者其他Binder Server服务），都需要打开一次Binder驱动、执行mmap，其后果就是消耗的系统资源会越来越多，直到崩溃。一个有效的解决办法是每个进程只允许打开一次Binder设备，且只做一次内存映射——所有需要使用Binder驱动的线程共享这一资源。

问题转化为：如果让我们来设计一个符合上述要求的Binder Client，应该怎么做？

1．ProcessState和IPCThreadState

首先能想到的是要创建一个类来专门管理每个应用进程中的Binder

操作——更为重要的是，执行Binder驱动的一系列命令对上层用户必须是“透明的”。

这个类就是ProcessState。

另外在Binder驱动小节中，我们看到binder_proc中有threads红黑树用于管理该进程中所有线程的IPC业务。这说明仅有ProcessState是不够的，进程中的每一个线程都应该有与Binder驱动自由沟通的权利——而且基于Binder的IPC是阻塞的，这样能保证个别thread在做进程间通信时不会卡死整个应用程序。

与Binder驱动进行实际命令通信的是IPCThreadState。

2．Proxy

有了上面两个类，应用程序现在可以与Binder驱动通信了。原则上我们还是可以通过发送BINDER_WRITE_READ等Binder支持的命令来与其交互，从而一步步得到SM提供的服务。不过这样的做法显然过于呆板和烦琐，聪明的读者一定能想到还需要对SM提供的服务进行封装。

把这个SM服务的封装取名为ServiceManagerProxy（字面意思就是“SM的代理”）如何？代理这个词在Binder中使用得较多，那么为什么称为代理呢？举个生活中的例子可能会让大家更清楚些。比如在中国大陆，留学生办理“国外学历认证”原则上是要到北京的教育部留学服务中心（cscse）的。我们假设留学服务中心提供的这个服务是cscse.getCertification(materials)，其中的materials代表办理该业务所要提供的所有有效证件材料。由于留学生很可能居住在全国各地，很少有人能专门前往北京办理。为了解决这个问题，服务中心便在各大城市都设立了自己的代理点，即cscseproxy。这些代理点为留学生提供的是本地的服务（Proxy和其使用者是在同一个进程中的）。而在业务办理上，如材料的要求方面，服务中心和所有办理点的标准肯定是一样的，即它们已经设定了统一的Icscse接口。

现在代理点正常营业了，那么它提供的接口是怎样的呢？

没错，是cscseproxy.getCertification(materials)，而且materials和cscse的要求也一定是完全一致的。对于留学生而言，他们通过本地的代理就成功实现了与远在北京的留学中心的“跨进程”交

互。最关键的是，那些烦琐的中间流程是不需要他们关心的，因为代理提供的接口和服务中心的接口并没有任何区别。

要设计ServiceManagerProxy，首先要明确我们要的最终效果是怎样的，即设计目标的设定。既然是封装，当然是希望提高这个模块与其他模块的无关性和便利性。比如下面的伪代码就给出了一个很好的例子，描述了应用程序如何通过ServiceManagerProxy来快速获取SM服务（这个例子是通过SM来查询WindowManagerService的Binder句柄。注意：下面的代码只是示范代理可以做成什么样子，和Android系统中真正的ServiceManagerProxy实现略有差异）：

```
/*应用程序获取SM服务示例*/
//Step1. 创建ServiceManagerProxy
ServiceManagerProxy sm = new ServiceManagerProxy(new BpBinder(HAN

//Step2. 通过ServiceManagerProxy获取SM的某项服务
IBinder   wms_binder =  sm.getService("window");
```

也就是说，应用程序只需要两步就可以得到ServiceManager提供的服务。

上面的代码示例的确可以给调用者带来便利，接下来的难点就是如何实现这个目标了。

（1）ServiceManagerProxy的接口。ServiceManagerProxy所能提供的服务和服务端的SM必须是一致的，如getService，addService等。把这些方法提取出来，就是ServiceManagerProxy的接口。我们给它取名为IServiceManager，如下所示（大家先忽略它的参数）：

```
public interface IServiceManager
{
     public IBinder getService(String name) throws RemoteExceptio
     public IBinder checkService(String name) throws RemoteExcept
     public void addService(String name, IBinder service, boolean
     public String[] listServices() throws    RemoteException;
}
```

很显然，ServiceManagerProxy需要继承自IServiceManager，如图6-15所示。

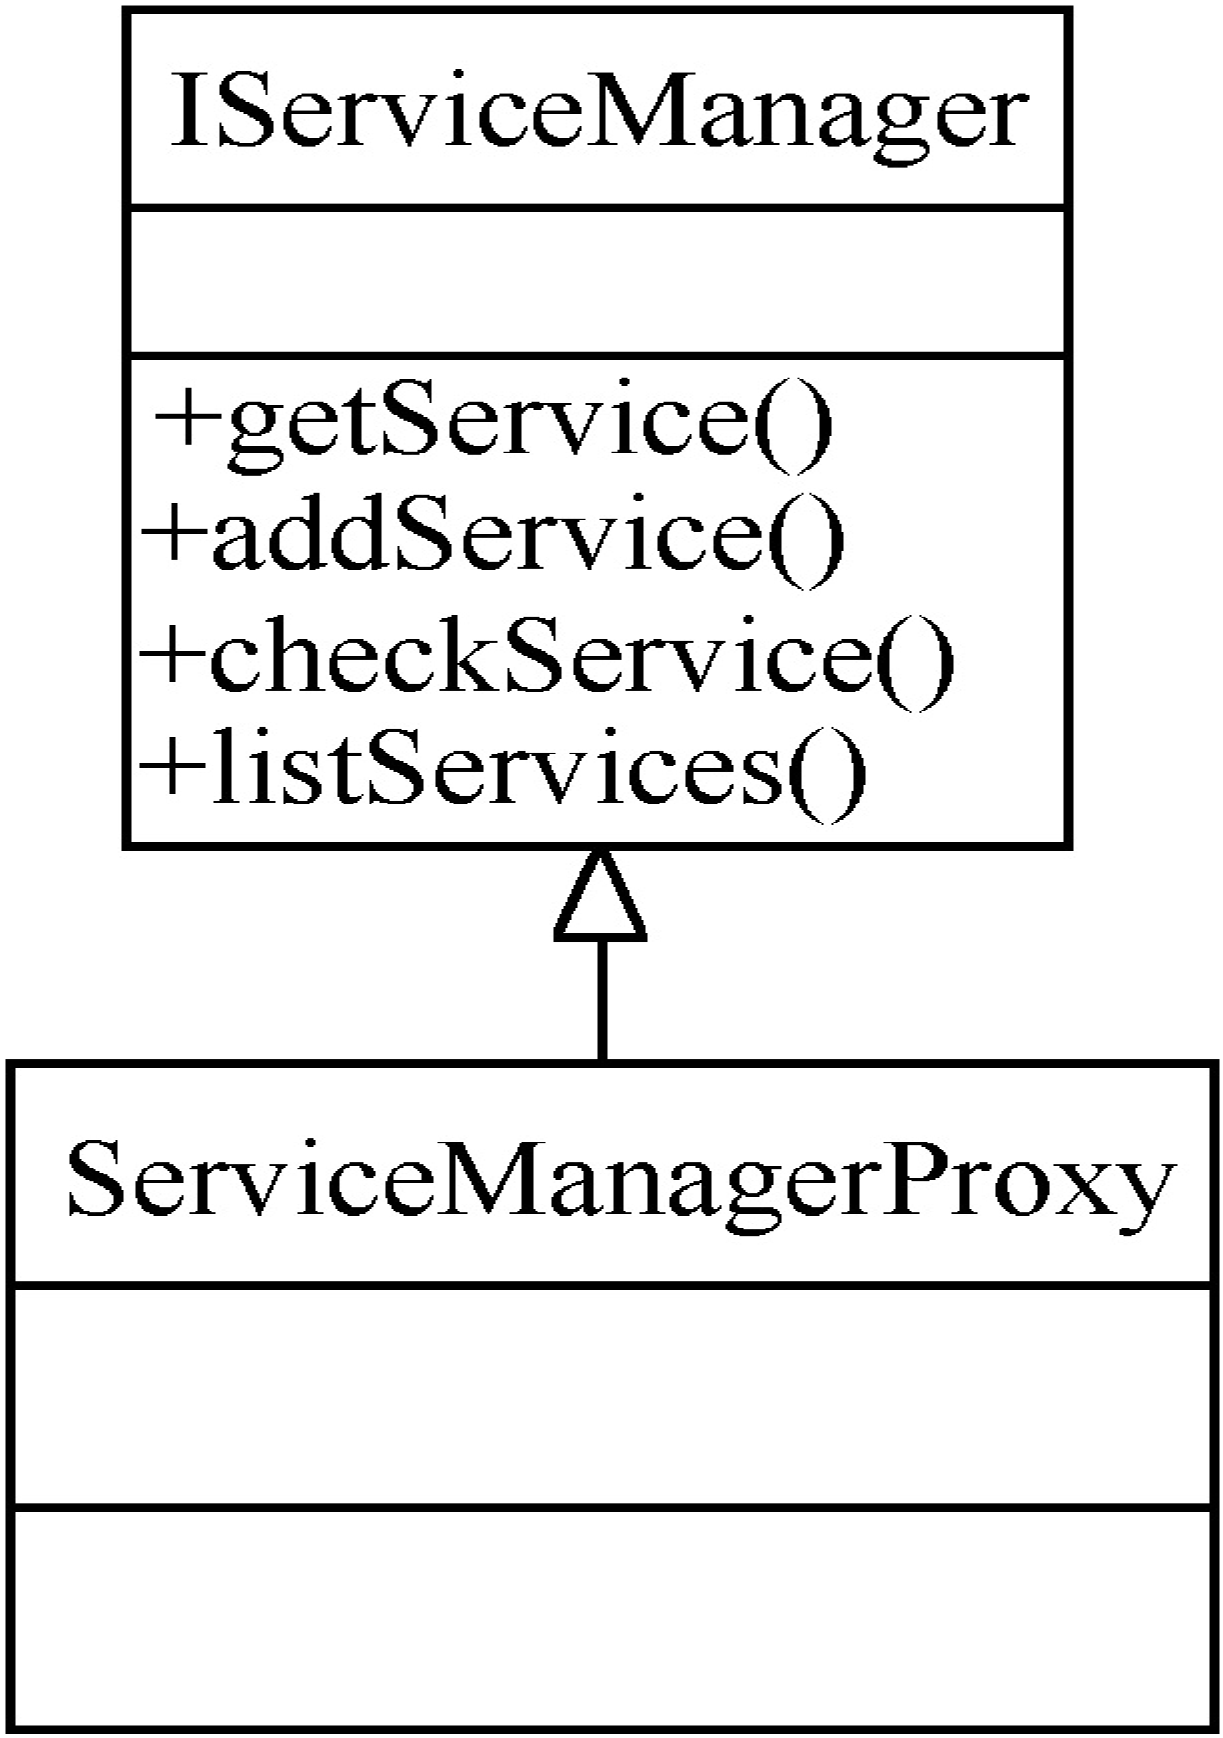
IServiceManager
+getService()
+addService()
+checkService()
+listServices()
ServiceManagerProxy

▲图6-15　继承自IServiceManager

（2）接口实现。以getService为例，要取得ServiceManager的这个服务，至少有两部分工作。

- 与Binder建立关系

因为进程中已经有了ProcessState和IPCThreadState这两个专门与Binder驱动通信的类，所以Java层代码使用Binder驱动实际上是基于它们来完成的。我们称为BpBinder。

- 向Binder发送命令，从而获得SM提供的服务。

这样以Service Manager为例，便从设计层面思考了Binder机制的“上层建筑”实现。希望大家在后续小节的源码分析中，可以紧紧抓住本小节推导出的设计思想，否则很容易迷失方向。

总结如下：

Binder机制确实是太繁杂了，它不仅涉及Binder驱动，而且还需要同时为Java，C/C++等各个系统层服务，所以各种类名和概念层出不穷——其调用流程用“山路十八弯”来形容一点不为过。

为了让大家更好地理解Binder原理，我们在这一小节中尽可能采用引导式的讲解方法，通过问题思考解答来尽可能还原Binder设计者的意图。到目前为止，读者应该至少明白了以下内容。

- Binder架构

它的主体包括驱动、SM、Binder Client和Binder Server。通过与经典的TCP/IP服务类比，我们不难理解每个模块的功能。

- Binder驱动

驱动是其他元素的基础。这一部分内容虽然代码较多，但并不算复杂，只要用心去看一定可以理解透彻。

- Service Manager

SM既是Binder框架的支撑者，同时也是一个标准的Server。因而我们以它为例向大家阐述了Binder Server的设计理念。在这一过程中出现了很多对象（如Proxy），不过都没有给出具体的源码（代码一多，大脑堆栈太深就容易溢出）。

可以用一张图来概括Binder机制，如图6-16所示。

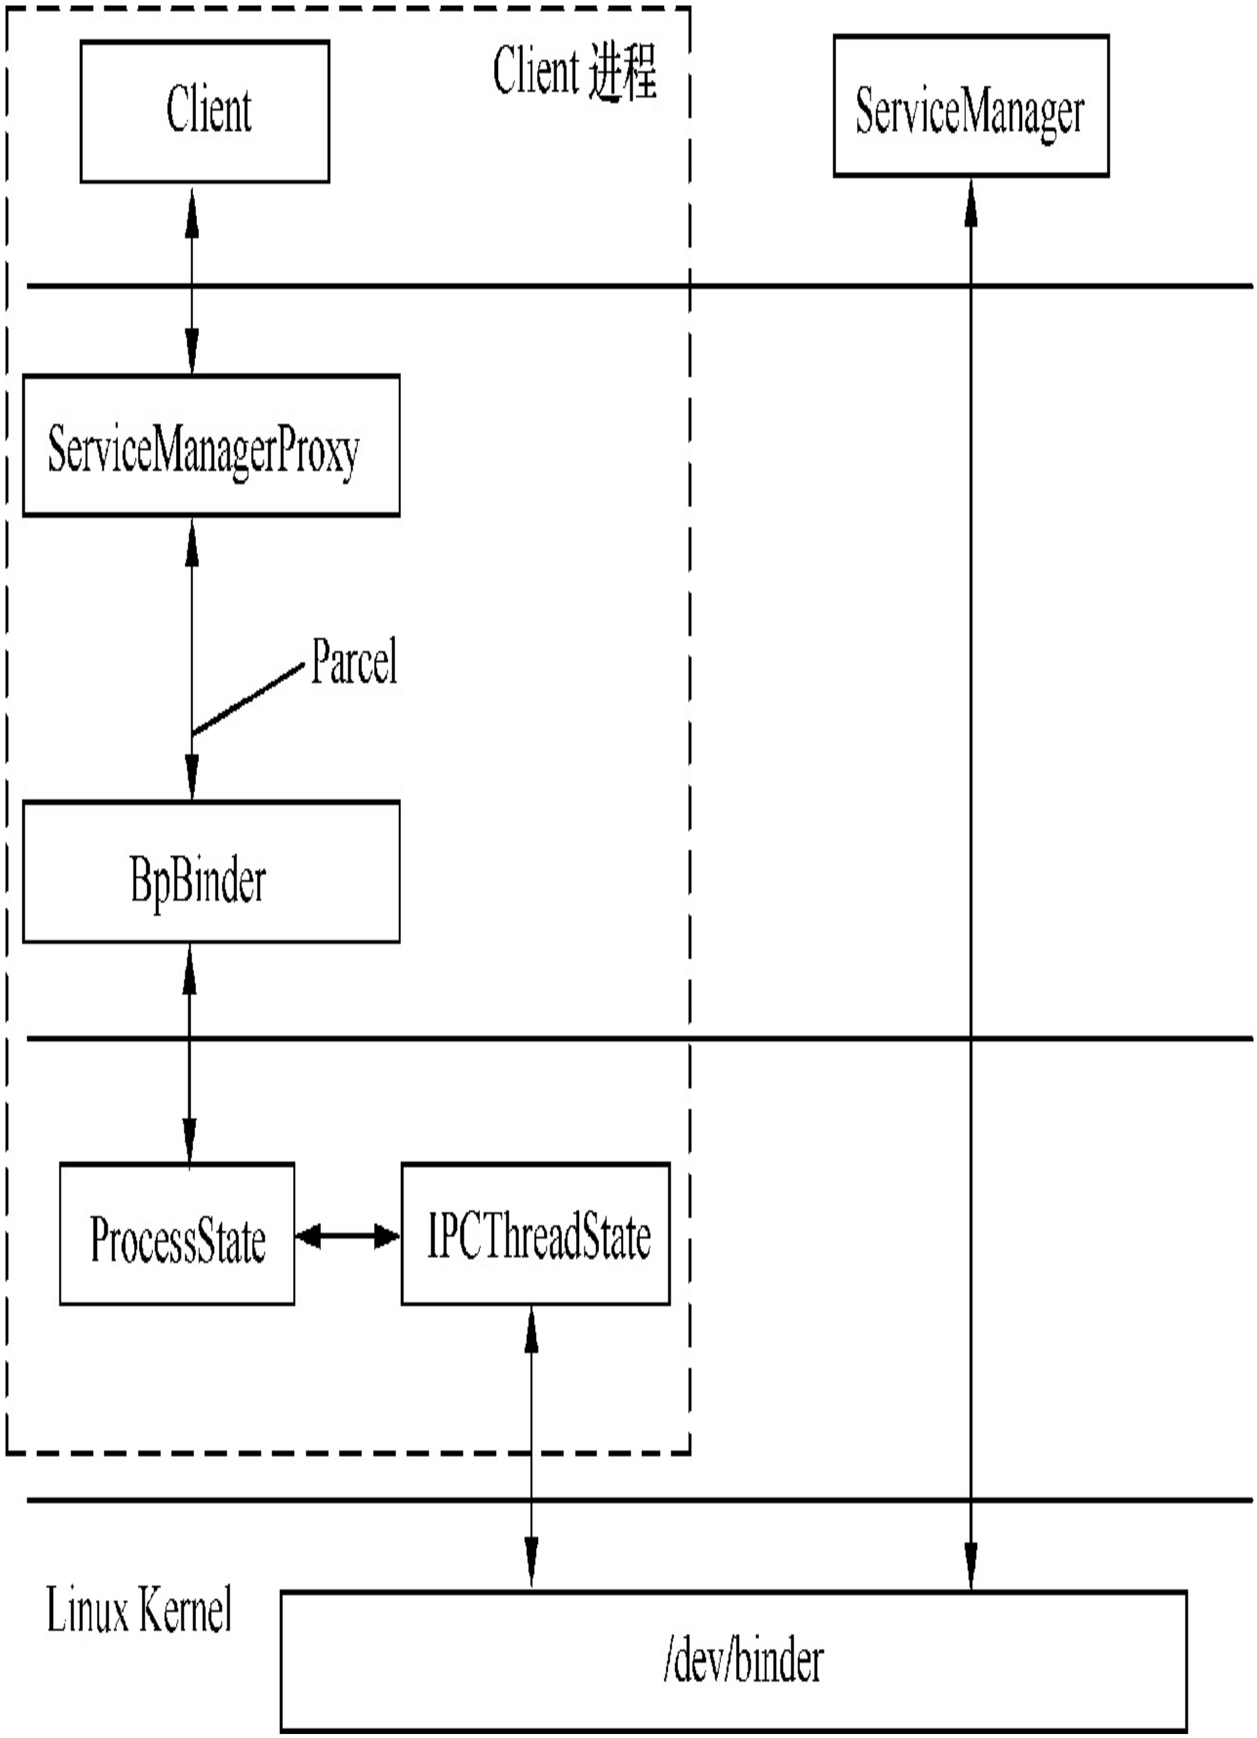

Client 进程
Client
ServiceManager
ServiceManagerProxy
Parcel
BpBinder
ProcessState
IPCThreadState
Linux Kernel
/dev/binder

▲图6-16　获取SM服务（主要组成元素）

图6-16中Client表示Binder Client，即使用Binder机制来获取服务的客户端。它的内部结构由下而上依次为ProcessState/IPCThreadState→BpBinder→Proxy→User。不论是Client或者Service Manager，它们的工作都是基于Binder Driver完成的。该图描绘了Binder模型中“上层建筑”的各个组成元素，如果大家在以后源码分析过程中迷失方向，请回到这里再次理顺它们所扮演的角色。

接下来我们就结合源码（以Service Manager的getService服务为重点贯穿整个分析过程）分别介绍ServiceManagerProxy、Binder封装以及ProcessState/IPCThreadState等。

6.4.4　ServiceManagerProxy

前一小节思考“设计意图”时，我们曾通过一小段伪代码描述了ServiceManagerProxy的一种实现方案——Android系统中的具体实现与此基本类似，只不过它在ServiceManagerProxy上又加了一层封装，即ServiceManager.java。

这样应用程序使用ServiceManager就更加方便了，连ServiceManagerProxy对象都不用创建，如下所示：

```
ServiceManager.getService(name);
```

因为ServiceManager中的所有服务接口都是static的，因而用户不需要额外创建任何类对象就可以直接使用SM的功能。我们来看看getService的内部实现。

```
/*frameworks/base/core/java/android/os/ServiceManager.java*/
public static IBinder getService(String name) {
   try {
       IBinder service = sCache.get(name);//查询缓存
       if (service != null) {
           return service;//从缓存中找到结果，直接返回
       } else {
             return getIServiceManager().getService(name);//
       }
```

```
        } catch (RemoteException e) {
              Log.e(TAG, "error in getService", e);
        }
        return null;
    }
```

这个函数的逻辑很简单，其中sCache用于记录getService的历史查询结果——所以程序每次都会首先到这里翻阅记录，以加快查询速度。如果不存在的话，才会调用getIServiceManager().getService发起一条查询请求：

```
    private static IServiceManager getIServiceManager() {
       if (sServiceManager != null) {
            return sServiceManager;//返回一个IServiceManager对象
       }
       // Find the service manager
       sServiceManager =ServiceManagerNative.asInterface(BinderIn
       return sServiceManager;
    }
```

程序首先判断sServiceManager是否为空，以防止多次重复操作。如果是第一次使用SM，则调用ServiceManagerNative.asInterface(BinderInternal.getContextObje
来获取一个IServieManager。到目前为止，我们还是没有看到ServiceMangerProxy，不过出现了一个新的类ServiceManagerNative：

```
     /*frameworks/base/core/java/android/os/ServiceManagerNative.
    static public IServiceManager asInterface(IBinder obj)
    {
        if (obj == null) {
            return null;
        }
        IServiceManager in = (IServiceManager)obj.queryLocalInter
        if (in != null) {
            return in;
        }
        return new ServiceManagerProxy(obj);
    }
```

从这个函数的注释可以发现，它负责将一个Binder对象转换成IServiceManager，并在必要的时候创建ServiceManagerProxy。

这里的IBinder对象（obj）是通过

BinderInternal.getContextObject()得到的，我们先不深究其内部实现，把它当成与底层Binder沟通的工具即可。函数的处理逻辑分为以下两部分。

- queryLocalInterface

  查询本地是否已经有IServiceManager存在。

- 如果没有查询到，则新建一个ServiceManagerProxy

这一小节的主角终于出现了，作为SM的代理，可想而知ServiceManagerProxy必定是要与Binder驱动通信的，因而它的构造函数中传入了IBinder对象：

```
public ServiceManagerProxy(IBinder remote) {
    mRemote = remote;
}
```

可以看到，它只是简单地记录了这个IBinder对象。这就像我们电话订餐一样，IBinder是餐馆的电话号码，通常都是先把它记下来，等需要的时候再通过这个号码获取餐馆提供的服务。比如getService()这个接口：

```
public IBinder getService(String name) throws RemoteException
   Parcel data = Parcel.obtain();
   Parcel reply = Parcel.obtain();
   data.writeInterfaceToken(IServiceManager.descriptor);
   data.writeString(name);
   mRemote.transact(GET_SERVICE_TRANSACTION, data, reply, 0);

   IBinder binder = reply.readStrongBinder();
   reply.recycle();
   data.recycle();
   return binder;
}
```

这个函数实现分为以下3部分。

- 准备数据

  也就是通过Parcel打包数据。在前面的小节对Parcel有专门的介

绍，不清楚的读者可以回头看看。

- IBinder.transact

利用IBinder的transact将请求发送出去，而不用理会Binder驱动的open，mmap以及一大堆具体的Binder协议中的命令。所以这个IBinder一定会在内部使用ProcessState和IPCThreadState来与Binder驱动进行通信。

- 获取结果

上面transact后，我们就可以直接获取到结果了。如果大家用过socket，就知道这是一种阻塞式的函数调用。因为涉及进程间通信，结果并不是马上就能获取到，所以Binder驱动一定要先将调用者线程挂起，直到有了结果才能把它唤醒。这样做的好处就是调用者可以像进程内函数调用一样去编写程序，而不必考虑很多IPC的细节。后面我们还会做详细分析。

是不是很简单？实际工作只有下面这句：

```
mRemote.transact(GET_SERVICE_TRANSACTION, data, reply, 0);
```

很多内部细节都已经隐藏起来了。这里需要注意一下，就是客户端和服务器端所使用的业务代码要一致，如上面的GET_SERVICE_TRANSACTION。它的定义是：

```
int GET_SERVICE_TRANSACTION = IBinder.FIRST_CALL_TRANSACTION;
```

按照IBinder的定义：

```
int FIRST_CALL_TRANSACTION  = 0x00000001;
```

所以这个业务码是1。

再来看Service_manager.c中的业务码说明：

```
enum {
    SVC_MGR_GET_SERVICE = 1, //对应的就是上面的那个业务
    SVC_MGR_CHECK_SERVICE,
    SVC_MGR_ADD_SERVICE,
    SVC_MGR_LIST_SERVICES,
};
```

这样客户端与服务器端的业务代码就保持一致了。值得一提的是，ServiceManger这个Binder Server比较特殊——它主动提供了上面这个enum结构来定义业务码。通常情况下，使用AIDL产生的Binder Server会自动生成这些业务码，而不需要手工编写。

6.4.5 IBinder和BpBinder

我们的目标是为应用程序使用ServiceManager服务提供便利的实现——其中的核心是ServiceManagerProxy，其外围又包装了ServiceManager.java和ServiceManagerNative，这些都在上一小节介绍过。

在创建ServiceManagerProxy时，传入了一个IBinder对象，然后借助于它的transact方法，可以方便地与Binder驱动进行通信。那么，IBinder内部是如何实现的？这就是本小节的讲解重点。

和ServiceManagerProxy一样，用户希望能通过尽可能精简的步骤来使用Binder的功能。Binder提供的功能可以统一在IBinder中表示，至少要有如下接口方法：

```
/*frameworks/base/core/java/android/os/IBinder.java*/
public interface IBinder {
     public IInterface queryLocalInterface(String descriptor);
     public boolean transact(int code, Parcel data, Parcel reply,
                        throws Remote Exception;
     …
}
```

此外，还应该有获取IBinder对象的一个类，即BinderInternal。提供的相应方法是：

```
/*frameworks/base/core/java/com/android/internel/os/BinderInterna
public class BinderInternal {
     public static final native IBinder getContextObject();
     …
}
```

大家一定注意到了，这个方法是native的。因为和Binder驱动打交道，最终都得通过JNI调用本地代码来实现。这样我们还得写JNI层的BinderInternal，如下所示：

```
/*frameworks/base/core/jni/android_util_Binder.cpp*/
static jobject android_os_BinderInternal_getContextObject(JNIEnv*
{
    sp<IBinder> b = ProcessState::self()->getContextObject(NULL);
    return javaObjectForIBinder(env, b);
}
```

有的读者可能会奇怪为什么取名为ContextObject呢？Context即“背景、上下文”，这里可以理解为运行时态的上下文。换句话说，是因为IPC和整个Process或者Thread都是有紧密关联的。更进一步，基本上每个Process都需要IPC通信。既然如此，IPC就可以作为进程的基础配置存在。作为IPC中的基础元素之一，Binder就是这个Context中的重要一环，因而称为ContextObject。

我们再回到getContextObject这个方法中来。和预想的一样，它确实是通过ProcessState来实现的，后一个小节会做具体分析。然后把

ProcessState中创建的对象转化成Java层的IBinder对象。

IBinder只是一个接口类，显然还会有具体的实现类继承于它。在Native层，这就是BpBinder（BpBinder.cpp）；而在Java层，则是Binder.java中的BinderProxy。事实上，ProcessState::self() ->getContextObject(NULL)返回的就是一个BpBinder对象。图6-17描述了它们的关系。

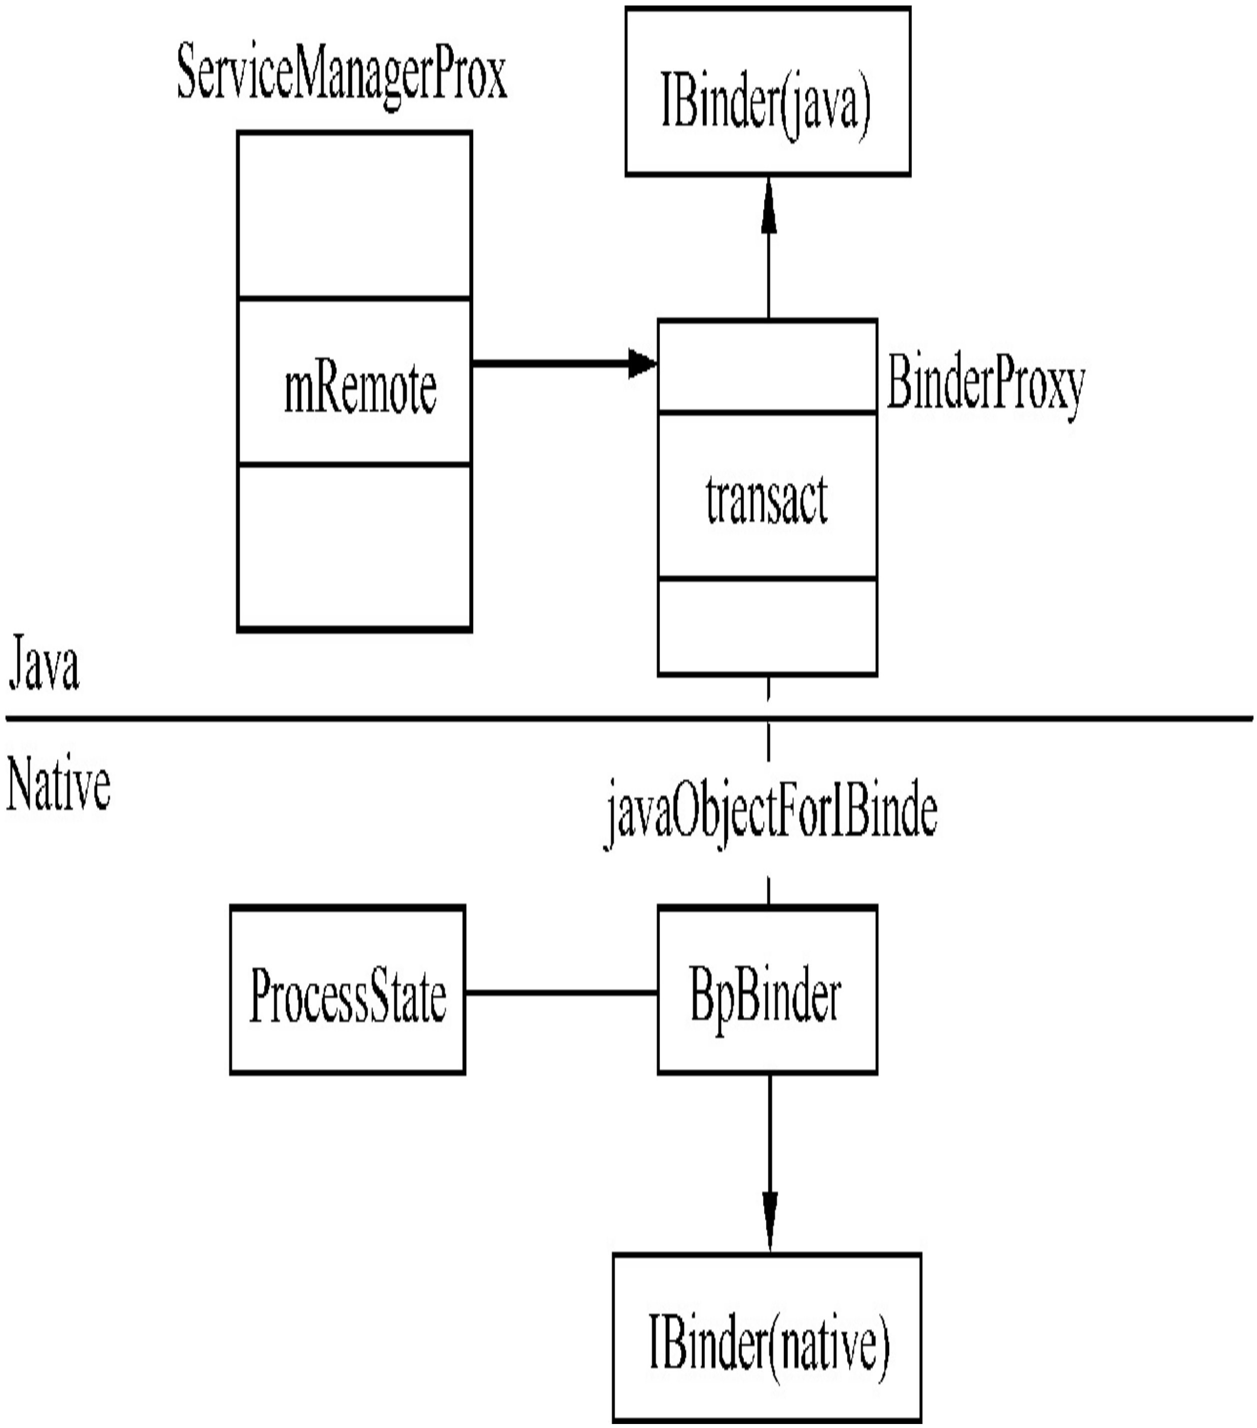

▲图6-17　BinderProxy和BpBinder的关系简图

BinderProxy和BpBinder分别继承自Java和Native层的IBinder接口。其中BpBinder是由ProcessState创建的，而BinderProxy是由javaObjectForIBinder()函数通过JNI的NewObject()创建的。

下面看看调用mRemote->transact时的实现：

```
/*frameworks/base/core/java/android/os/Binder.java*/
final class BinderProxy implements IBinder {
    public native boolean transact(int code, Parcel data, Parcel
           int flags) throws RemoteException;
     …
}
```

BinderProxy中的transact就是一个native接口，真正的实现还是在android_util_Binder.cpp中（这个文件容纳了很多类的实现，因而显得很杂）：

```
static jboolean android_os_BinderProxy_transact(JNIEnv* env, jobj
       jint code, jobject dataObj, jobject replyObj, jint flags)
{
    …
    Parcel* data = parcelForJavaObject(env, dataObj);
    …
    Parcel* reply = parcelForJavaObject(env, replyObj);
    …
    IBinder* target = (IBinder*)env->GetIntField(obj, gBinderProx
    …
    status_t err = target->transact(code, *data, reply, flags);
    …
    signalExceptionForError(env, obj, err, true /*canThrowRemoteE
    return JNI_FALSE;
}/*android_os_BinderProxy_transact结束*/
```

传参中的dataObj和replyObj分别对应BinderProxy.transact中的第2、3个参数（即Parcel data和Parcel reply），需要先把它们转成native中的Parcel实现。

可以猜想到的是，前面通过javaObjectForIBinder将一个BpBinder转化成BinderProxy，这里一定会做反向转化。全局变量gBinderProxyOffsets.mObject记录的是BinderProxy中mObject的jfieldID，后面就可以通过JNI的GetIntField来获得这个int值了，即BpBinder对象的内存地址（可以参考本书JNI章节的介绍）。

最后就是通过BpBinder.transact来处理用户的Binder请求：

```
/*frameworks/native/libs/binder/BpBinder.cpp*/
status_t BpBinder::transact(uint32_t code, const Parcel& data, Pa
```

```
{
    // Once a binder has died, it will never come back to life.
    if (mAlive) {
        status_t status=IPCThreadState::self()->transact(mHandle,
        if (status == DEAD_OBJECT) mAlive = 0;
        return status;
    }
    return DEAD_OBJECT;
}
```

此时发现绕了个大大的圈子，最终还是通过IPCThreadState及ProcessState来实现的，这也验证了我们之前的设想。因为Android既有Java应用程序，又有Native层实现，所以导致整个结构看起来非常复杂。我们在下一小节会详细讲解这两个类的实现。

6.4.6 ProcessState和IPCThreadState

本小节将重点分析ProcessState和IPCThreadState。

其中实现ProcessState的关键点在于。

- 保证同一个进程中只有一个ProcessState实例存在；而且只有在ProcessState对象创建时才打开Binder设备以及做内存映射。
- 向上层提供IPC服务。
- 与IPCThreadState分工合作，各司其职。

以下是ProcessState的源码路径：/frameworks/native/libs/binder。

第一个问题很好解决，源代码如下所示：

```
/*/frameworks/native/libs/binder/ProcessState.cpp*/
sp<ProcessState> ProcessState::self()
{
    Mutex::Autolock _l(gProcessMutex);
    if (gProcess != NULL) {
        return gProcess;
    }
    gProcess = new ProcessState;//创建对象
    return gProcess;
}
```

从上面的代码段可以知道，访问ProcessState需要使用ProcessState::Self()。如果当前已经有实例（gProcess不为空）存在，就直接返回这个对象；否则，新建一个ProcessState。它的构造函数如下：

```
ProcessState::ProcessState()
    : mDriverFD(open_driver()) //要注意这里“别有洞天”
    , mVMStart(MAP_FAILED), mManagesContexts(false)
    , mBinderContextCheckFunc(NULL), mBinderContextUserData(NULL)
    , mThreadPoolStarted(false), mThreadPoolSeq(1)
{
     if (mDriverFD >= 0) {  //成功打开/dev/binder
     #if !defined(HAVE_WIN32_IPC)
       mVMStart = mmap(0, BINDER_VM_SIZE, PROT_READ, MAP_PRIVATE
                       mDriverFD, 0); /*开始执行mmap，内存块大小为：
                              BINDER_VM_SIZE=((1*1024*1024)-(4096
       …
     #else
         mDriverFD = -1;
     #endif
}
```

ProcessState的构造函数中初始化了很多变量——最重要的是，它调用open_driver()打开了/dev/binder节点。我们再复习一下使用Binder驱动所需要做的准备工作：首先是打开binder节点，然后执行mmap()——具体而言，映射的内存块大小为BINDER_VM_SIZE。

前面小节中我们在获取IBinder时使用了BinderInternal中的getContextObject()，这个方法最终的实现就是在ProcessState中。如下所示：

```
sp<IBinder> ProcessState::getContextObject(const sp<IBinder>& cal
{
    return getStrongProxyForHandle(0); //传入0，代表Service Manager
}
```

接着看下面的函数实现：

```
sp<IBinder> ProcessState::getStrongProxyForHandle(int32_t handle)
{
    sp<IBinder> result; //需要返回的IBinder
    AutoMutex _l(mLock);

handle_entry* e = lookupHandleLocked(handle);/*查找一个Vector表mHar
```

```
                                               这里保存了这个进程已经建立的E
    if (e != NULL) { /*如果上面的表中没有找到相应节点，会自动添加一个。
                      所以这里的变量e正常情况下都不会为空*/
        IBinder* b = e->binder;
        if (b == NULL || !e->refs->attemptIncWeak(this)) {
            b = new BpBinder(handle); //BpBinder出现了
            e->binder = b;
            if (b) e->refs = b->getWeakRefs();
            result = b;
        } else {
          result.force_set(b);
                 e->refs->decWeak(this);
        }
    }
    return result;
}
```

通过上面的代码，我们知道ProcessState中有一个全局列表来记录所有与Binder对象相关的信息，而每个表项是一个handle_entry，包含了如下数据：

```
      struct handle_entry {
             IBinder* binder;
             RefBase::weakref_type* refs;
       };
```

其中的binder属性实际上是一个BpBinder，而且程序只有在以下两种情况下才会生成一个BpBinder。

- 在列表中没有找到对应的BpBinder。
- 虽然从列表中查找到了对应的节点，但是没有办法顺利对这个BpBinder增加weak reference。

BpBinder在之前的Binder封装中已经介绍过，它是Native层的Binder代理，最后会由javaObjectForIBinder转化为Java层的BinderProxy。我们来看看它的构造函数：

```
/*BpBinder.cpp*/
BpBinder::BpBinder(int32_t handle)
   : mHandle(handle) //如果是SM，handle为0
   , mAlive(1), mObitsSent(0), mObituaries(NULL)
{…
   extendObjectLifetime(OBJECT_LIFETIME_WEAK);
```

```
    IPCThreadState::self()->incWeakHandle(handle);
}
```

我们在这个构造函数中看到了一个熟悉的智能指针的设置方法，即extendObjectLifetime（OBJECT_LIFETIME_WEAK），说明这个BpBinder一定会继承于提供引用计数的基类。具体而言，BpBinder的父类是Ibinder。而后者：

```
class IBinder : public virtual RefBase
```

可见BpBinder所使用的引用计数基类是RefBase，它同时支持强弱两种引用计数。在这里设置了OBJECT_LIFETIME_WEAK，表示目标对象的生命周期受弱指针控制。这样ProcessState:: getContextObject就得到了一个BpBinder，并且其中的mHandle代表了这个Proxy的主人（比如SM就是0），之后传递给Client时才转换成IBinder。

IPCThreadState又是什么时候出场的呢？可以这么说，有需要的时候才会创建。为了和ProcessState一样保持“单实例”，我们也需要通过IPCThreadState::self()来访问它——只不过前者是“进程中的单实例”，而后者是“线程中的单实例”。

我们知道，同一个进程中的全局变量是可以在多个线程中访问到的。这种做法一方面给程序带来了便利，另一方面也有其劣势。比如访问这些变量需要同步机制的配合，在一定程度上降低了执行效率。另外，有的变量则希望只在本线程内是全局的，其他线程是无法访问到的——显然纯粹的全局变量无法满足这个要求。

TLS（Thread Local Storage）机制就是为了解决上述这个问题而提出来的。它能保证某个变量仅在自己线程内访问有效，而其他线程中得到的是这个变量的独立复本，互不干扰：

```
/*frameworks/native/libs/binder/IPCThreadState.cpp*/
IPCThreadState* IPCThreadState::self()
{
    if (gHaveTLS) { //这个变量的初始值为false
restart:  //当启用TLS后，重新回到这
       const pthread_key_t k = gTLS;
       IPCThreadState* st = (IPCThreadState*)pthread_getspecific(
       if (st) return st;
        return new IPCThreadState;
    }
```

```
    if (gShutdown) return NULL;

    pthread_mutex_lock(&gTLSMutex);
    if (!gHaveTLS) {
        if (pthread_key_create(&gTLS, threadDestructor) != 0) {
            pthread_mutex_unlock(&gTLSMutex);
            return NULL;
        }
        gHaveTLS = true; //以后都是TLS了
    }
    pthread_mutex_unlock(&gTLSMutex);
    goto restart;//返回restart接着执行
}
```

我们来仔细分析上面这个函数的逻辑。

当第一次被调用时，gHaveTLS为false，因而不会进入第一个if判断中，也不会创建IPCThreadState。但是随后它就会进入第二个if判断并启动TLS，然后返回restart处新建一个IPCThreadState。当以后再被调用时，gHaveTLS为true：如果本线程已经创建过IPCThreadState，那么pthread_getspecific就不为空；否则返回一个新建的IPCThreadState。

这样我们就有效地保证了“线程单实例”的目的。

下面来看看IPCThreadState的构造函数以及几个重要变量：

```
IPCThreadState::IPCThreadState()
   : mProcess(ProcessState::self()), //ProcessState整个进程只有一个
     mMyThreadId(androidGetTid()), //当前的线程id
     mStrictModePolicy(0), mLastTransactionBinderFlags(0)
{
    pthread_setspecific(gTLS, this);
    clearCaller();
    mIn.setDataCapacity(256); /*mIn是一个Parcel，从名称可以看出来，它是
                                Binder发过来的数据的，最大容量为256*/
    mOut.setDataCapacity(256); /*mOut也是一个Parcel，它是用于存储要发
                                        的命令数据的，最大容量为256*/
}
```

前面BpBinder构造函数的最后调用了IPCThreadState的incWeakHandle用于增加Binder Service的弱引用计数值（这里指Service Manager），它实际上是向Binder驱动发送了一个BC_INCREFS

命令。如下所示：

```
void IPCThreadState::incWeakHandle(int32_t handle)
{
    LOG_REMOTEREFS("IPCThreadState::incWeakHandle(%d)\n", handle)
    mOut.writeInt32(BC_INCREFS);
    mOut.writeInt32(handle);
}
```

除此之外，还有decWeakHandle，incStrongHandle，decStrongHandle来与Binder协议中的其他命令相对应。

IPCThreadState负责与Binder驱动进行具体的命令交互（ProcessState只是负责打开了Binder节点并做mmap），因而它的transact函数非常重要。下面我们就看看其内部的实现（分段阅读）：

```
status_t IPCThreadState::transact(int32_t handle, uint32_t code,
                                  Parcel* reply, uint32_t flags)
{
```

大家还记得吗？我们一直是以ServiceManager提供的getService()方法为线索来追踪代码的。到目前为止调用流程是这样的：

getService@ServiceManagerProxy→transact@BinderProxy→trans ThreadState。

针对getService，transact函数中各参数的值分别是：

- handle是0；
- code为GET_SERVICE_TRANSACTION；
- data。

getService@ServiceManagerProxy函数中对data的操作代码摘录如下：

```
data.writeInterfaceToken (IServiceManager.descriptor);
data.writeString(name);/*这里的name是指要查询的服务名，如“window”表示
                         WindowManagerService*/。
```

- flags为0

函数一开始会对data进行检查：

```
status_t err = data.errorCheck(); //检查data是否有效
flags |= TF_ACCEPT_FDS;
```

Transaction共有4种flag，如下所示。

TF_ONE_WAY：这个名字取得有点怪，它表示当前业务是异步的，不需要等待。

TF_ROOT_OBJECT：所包含的内容是根对象。

TF_STATUS_CODE：所包含的内容是32-bit的状态值。

TF_ACCEPT_FDS = 0x10：允许回复中包含文件描述符。

因为开始的flags为0，所以经过这一步后flags的值是TF_ACCEPT_FDS。

接下来transact就要整理数据，把它打包成Binder驱动协议规定的格式了。这个过程由writeTransactionData来完成（注意：这个函数只是整理数据，并把结果存入mOut中。而在talkWithDriver()方法中才会将命令真正发送给Binder驱动）：

```
if (err == NO_ERROR) {
   LOG_ONEWAY(">>>> SEND from pid %d uid %d %s", getpid(), ge
       (flags & TF_ONE_WAY) == 0 ? "READ REPLY" : "ONE WAY");
   err = writeTransactionData(BC_TRANSACTION, flags, handle,c
}
```

出错处理：

```
if (err != NO_ERROR) {
    if (reply) reply->setError(err);
    return (mLastError = err);
}
```

到目前为止，命令还在mOut中。那么，什么时候才会发出去呢？

```
if ((flags & TF_ONE_WAY) == 0) { //不是异步，根据上面的flags可知走
    if (reply) {//reply对象不为空
          err = waitForResponse(reply); //看起来应该是在这里面发送
```

```
        } else {
              Parcel fakeReply;//做一个假的reply对象
              err = waitForResponse(&fakeReply);
        }
          …
    } else { //异步的情况
          err = waitForResponse(NULL, NULL);
    }
    return err;
}/*transact结束*/
```

到目前为止，transact只是把transaction数据按照Binder协议的要求填写好了。它至少还有几件事要做：

- BC_TRANSACTION属于BINDER_WRITE_READ的子命令，因而数据外面还要再包一层描述信息。
- 数据还没有真正发送出去。
- 之前我们已经说过基于Binder的IPC多半都是阻塞型的，但是还没看到具体是如何实现的。

我们先来看看waitForResponse做了些什么工作：

```
status_t IPCThreadState::waitForResponse(Parcel *reply, status_t
{
    int32_t cmd;
    int32_t err;
    while (1) { //循环等待结果
       if ((err=talkWithDriver()) < NO_ERROR) break; /*处理与Binde
       err = mIn.errorCheck();
       if (err < NO_ERROR) break; //出错退出
       if (mIn.dataAvail() == 0) continue; //mIn中没有数据，继续循环
       cmd = mIn.readInt32(); //读取回复数据
        //接下来是对回复数据的处理，我们暂时略过，后面再回过头来分析
    …
}/*waitForResponse结束*/
```

上面代码段中的reply不为空，acquireResult为空。

实际上函数waitForResponse解决了前面提出的3个问题。其中talkWithDriver（这个函数后面有详细分析）会将已有数据进行必要的包装，然后发送给Binder驱动。接下来根据用户的配置会决定是否要等待结果：当程序走到mIn.errorCheck()时，说明已收到Binder驱动的回

复。这通常意味着Binder Server已经执行了相关请求（比如getService），并返回了结果。

为了让大家能将整个过程连贯起来，我们先不看waitForResponse对回复的处理，而是接着分析talkWithDriver这个函数。

IPCThreadState中与Binder驱动真正进行通信的地方就在talkWithDriver里，如下所示（分段阅读）。

```
status_t IPCThreadState::talkWithDriver(bool doReceive)
{
    if (mProcess->mDriverFD <= 0) {//Binder驱动设备还没打开
        return -EBADF;
    }
    binder_write_read bwr; /*读写都使用这个数据结构*/
    const bool needRead = mIn.dataPosition() >= mIn.dataSize();
    const size_t outAvail = (!doReceive || needRead) ? mOut.dataS
```

当mIn需要去读取（needRead），同时调用者又希望读取时（即doReceive为true），我们就不能写mOut。

Parcel(mIn)的数据处理如图6-18所示。

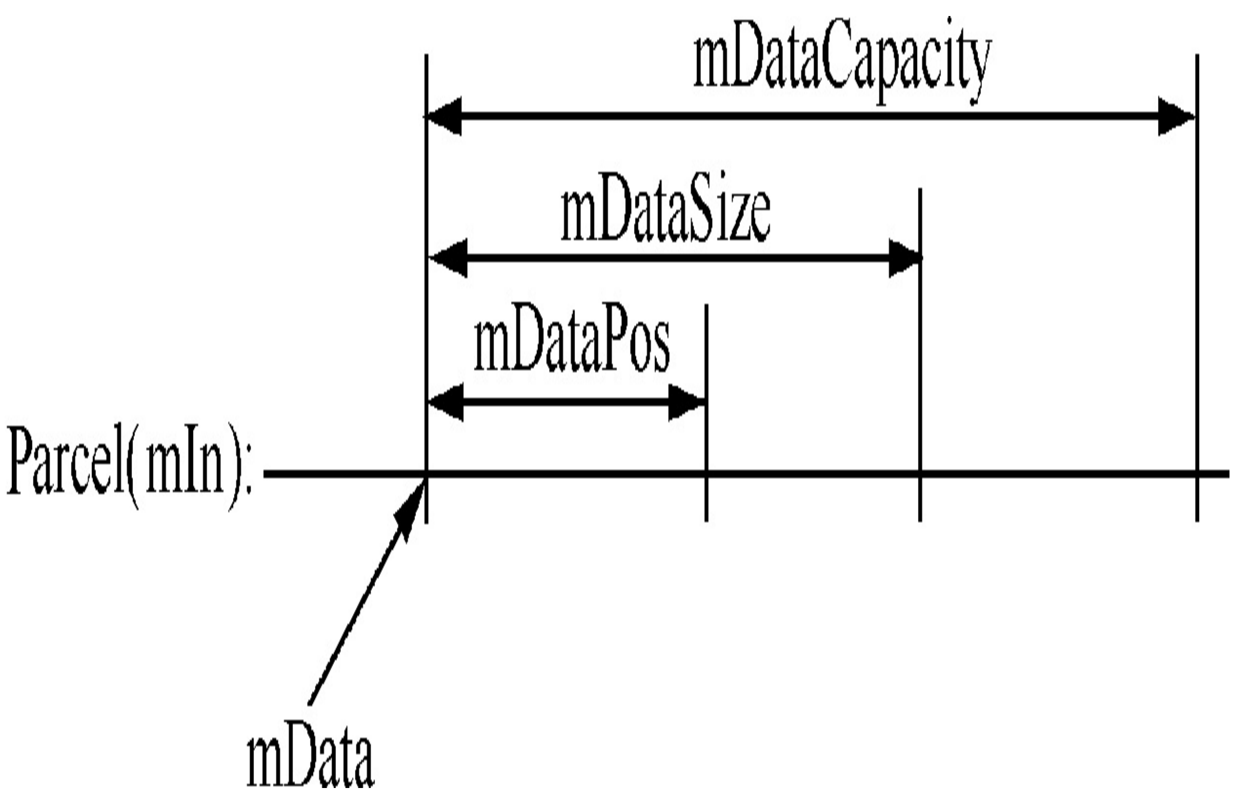

▲图6-18　Parcel (mIn)的数据处理图示

在前面小节中，我们介绍过Parcel中有几个重要的内部变量mData，mDataSize，mDataCapacity，mDataPos等。其中mData是指向某个内存地址的，表示Parcel所包含的内部数据在内存中的起始地址。而其他变量则是相对于mData来计算的，如mDataSize是指当前Parcel中已经有的数据量；mDataPos是当前已经处理过的数据量。

顺便分析下mOut，大家可以进行比较，如图6-19所示。

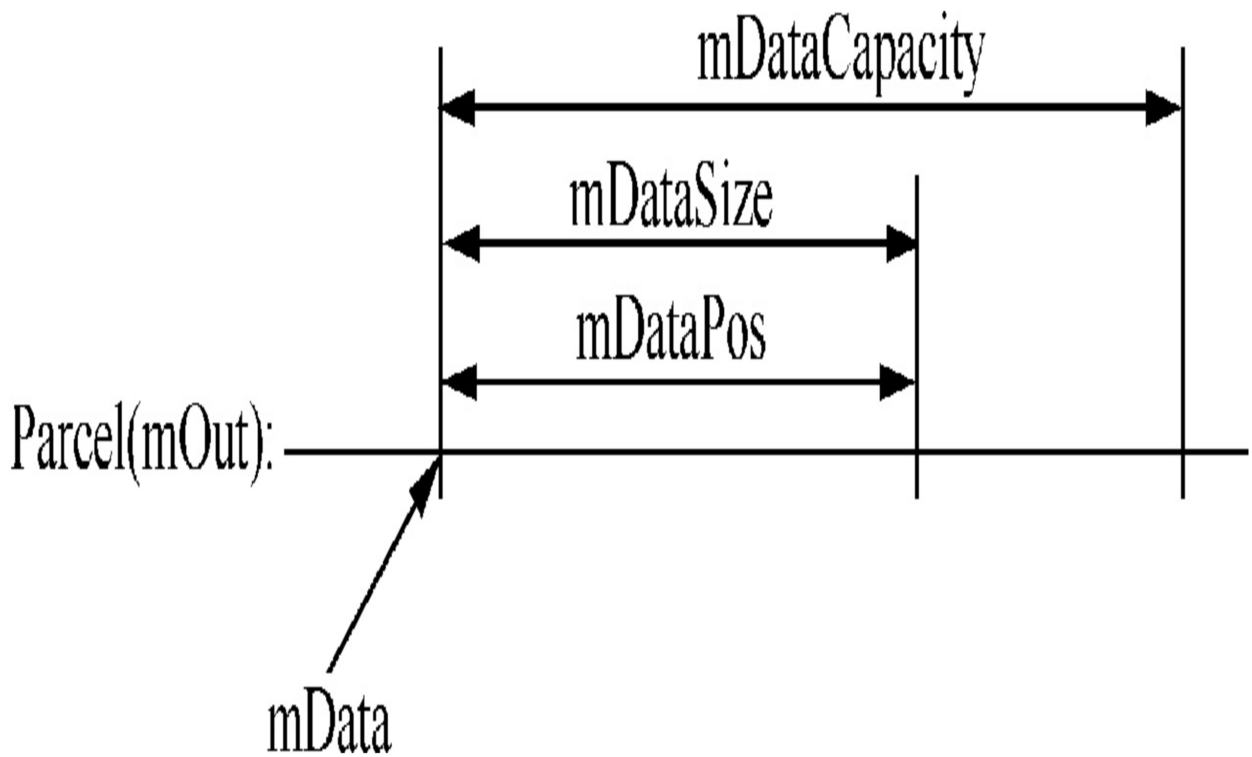

▲图6-19　Parcel (mOut)的数据处理图示

因为mDataPos表示“当前已经处理过的数据量”，对于mIn来说，读取数据就是“处理”；而对于mOut来说，写入才是“处理”，所以两者会有一定的差异。可想而知，当mOut要变成mIn时（A给B传parcel，对于A来说是写入，对于B则是读取）这些内部变量需要进行相应的调整，后面将看到：

```
bwr.write_size = outAvail;
bwr.write_buffer = (long unsigned int)mOut.data();
```

在bwr中填写需要write的内容和大小：

```
if (doReceive && needRead) {
    bwr.read_size = mIn.dataCapacity();
    bwr.read_buffer = (long unsigned int)mIn.data();
} else {
    bwr.read_size = 0;
    bwr.read_buffer = 0;
}
```

然后在bwr中填写需要read的数据请求：

```
…
if ((bwr.write_size == 0) && (bwr.read_size == 0)) return NO_
```

如果请求中既没有要读的数据，也没有要写的数据，那么就直接返回：

```
bwr.write_consumed = 0;
bwr.read_consumed = 0;
status_t err;
do {
 #if defined(HAVE_ANDROID_OS)//如果是Android系统
      if (ioctl(mProcess->mDriverFD, BINDER_WRITE_READ, &bwr)
          err = NO_ERROR;
      else
          err = -errno;
 #else
    err = INVALID_OPERATION;
 #endif
  …
} while (err == -EINTR);
```

这个循环的条件是err为-EINTR，因而一般情况下不会发生。真正与Binder驱动进行通信的代码只有一句，即：

```
ioctl(mProcess->mDriverFD, BINDER_WRITE_READ, &bwr);
```

稍后我们进入Binder驱动进行详细的情景分析：

```
if (err >= NO_ERROR) {
    if (bwr.write_consumed > 0) {
        if (bwr.write_consumed < (ssize_t)mOut.dataSize())
            mOut.remove(0, bwr.write_consumed);
        else
```

```
                mOut.setDataSize(0);
        }
        if (bwr.read_consumed > 0) {
            mIn.setDataSize(bwr.read_consumed);
            mIn.setDataPosition(0);
        }…
        return NO_ERROR;
    }
    return err;
}
```

执行完ioctl后，通过bwr.write_consumed和bwr.read_consumed可以知道Binder驱动对我们请求的BINDER_WRITE_READ命令的处理情况，然后对mIn和mOut做善后清理。

- write_consumed>0

说明Binder驱动消耗了mOut中的数据，因而就要把这部分已经处理过的数据移除掉。这分为两种情况：如果消耗的数据量小于mOut中的总数据量，就单独去掉这部分数据；否则，就直接设置当前总数据量为0。

- read_consumed>0

和上面的判断类似，此时说明Binder驱动已经成功帮我们读取到了数据，并写入了mIn.data()所指向的内存地址（即前面图6-19中所示的mData指针）中。所以，设置mDataSize和mDataPos为合适的值。

前面Binder驱动小节中曾经讨论过binder_ioctl这个函数的实现，但因为当时还缺乏具体的应用场景而没有做细致分析。现在我们就可以带着getService()这个请求再次进入函数的源码中。

接下来重点看看BINDER_WRITE_READ命令的执行过程（分段阅读）：

```
/*(内核工程) drivers/staging/android/Binder.c*/
static long binder_ioctl(struct file *filp, unsigned int cmd, uns
{
     int ret;
     struct binder_proc *proc = filp->private_data; /*从filp中取出p
                                binder_open中动态创建的实例*/
     struct binder_thread *thread;
```

```
    unsigned int size = _IOC_SIZE(cmd); //命令的大小
    void __user *ubuf = (void __user *)arg;
```

我们知道，Binder的执行过程多数是阻塞型的（或者说是同步操作）。换句话说，通过Binder去调用服务进程提供的接口函数，那么此函数执行结束时结果就已经产生，不涉及回调机制。比如用户使用getService向ServiceManager发起查询请求——函数的返回值就是查询的结果，意味着用户不需要提供额外的回调函数来接收结果。

Binder是如何做到这一点的呢？可以想到的方法有很多，其中常见的一种就是让调用者进程暂时挂起，直到目标进程返回结果后，Binder再唤醒等待的进程。如下所示：

```
ret = wait_event_interruptible(binder_user_error_wait, binder_sto
if (ret)
    goto err_unlocked;
```

这个wait_event_interruptible定义如下：

```
#define wait_event_interruptible(wq, condition)                \
({                                                        \
    int __ret = 0;                                        \
    if (!(condition))                                     \
        __wait_event_interruptible(wq, condition, __ret);      \
    __ret;                                                \
})
```

也就是说，如果condition满足的话就直接返回0；否则，调用__wait_event_interruptible进入可中断的挂起状态：

```
#define __wait_event_interruptible(wq, condition, ret)
do {                                                      \
    DEFINE_WAIT(__wait);                                    \
                                                          \
    for (;;) {                                            \
        prepare_to_wait(&wq, &__wait, TASK_INTERRUPTIBLE);
        if (condition)                                      \
            break;                                          \
        if (!signal_pending(current)) {                         \
            schedule();                                     \
            continue;                                     \
        }                                                 \
        ret = -ERESTARTSYS;                                  \
        break;                                               \
```

```
    }                                        \
    finish_wait(&wq, &__wait);                   \
} while (0)
```

宏定义__wait_event_interruptible里有个for死循环，跳出循环的条件是condition已经满足要求。首先它将自己置为TASK_INTERRUPTIBLE，也就是可中断挂起状态，然后进行schedule调度。可想而知，因为已经不是处于可运行状态，所以将不再分配到CPU时间，直到有人把它唤醒。醒来后还是得先检查condition是否已经满足，否则将再次处于可中断挂起状态。

这里因为binder_stop_on_user_error是小于2的，所以不会被挂起：

```
binder_lock(__func__);
```

此时ioctl已经取出之前为用户创建的proc结构体，并计算出命令的大小。接下来的操作将在保护区中进行：

```
thread = binder_get_thread(proc);
if (thread == NULL) {
     ret = -ENOMEM;
     goto err;
}
```

上面的代码中，binder_get_thread将首先向proc中的threads链表查询是否已经添加了当前线程的节点，如果没有则插入一个表示当前线程的新节点。需特别注意的是，threads链表是按pid大小排序的，这样可以加快查询速度。

到目前为止准备工作结束，可以处理具体的命令了：

```
     switch (cmd) {
     case BINDER_WRITE_READ: {
          struct binder_write_read bwr;
          if (size != sizeof(struct binder_write_read)) {
               ret = -EINVAL;
               goto err;
          }
```

首先判断buffer大小是否符合要求，然后开始从用户空间复制数据：

```
if (copy_from_user(&bwr, ubuf, sizeof(bwr))) {//从用户空间
     ret = -EFAULT;
     goto err;
}
…
```

还记得我们在ioctl_mmap中的讲解吗？如果还不太清楚上面代码是做什么的，请返回Binder驱动小节进行复习。

成功从用户空间取得数据后，接下来就开始执行write/read操作。

在talkWithDriver中，我们根据实际情况分别填写了write和read请求，因而这里也会区分对待：

```
if (bwr.write_size > 0) { //有数据需要写
     ret = binder_thread_write(proc, thread, (void __user
         bwr.write_size, &bwr.write_consumed); /*这个函数我
     if (ret < 0) { //成功执行返回0，负数表示有错误发生
         bwr.read_consumed = 0; //告诉调用者已读取的数据大小为
         if (copy_to_user(ubuf, &bwr, sizeof(bwr)))/*复制数
              ret = -EFAULT;
         goto err;
    }
}
```

上面这段代码首先判断用户是否请求写入数据，然后调用binder_thread_write：

```
if (bwr.read_size > 0) { //需要读数据
     ret = binder_thread_read(proc, thread, (void __user
        bwr.read_size,&bwr.read_consumed, filp->f_flags
                                          这个函数来读
     if (!list_empty(&proc->todo))
          wake_up_interruptible(&proc->wait);
     if (ret < 0) {
          if (copy_to_user(ubuf, &bwr, sizeof(bwr)))
               ret = -EFAULT;
          goto err;
     }
}
…
if (copy_to_user(ubuf, &bwr, sizeof(bwr))) {
     ret = -EFAULT;
     goto err;
}
```

```
         break;
     } //case BINDER_WRITE_READ结束
   …//其他命令处理过程省略
}//binder_ioctl结束
```

然后通过read_size判断用户是否请求读取数据。不管是读取还是写入，Binder驱动只是发挥中间人的作用，真正处理请求的还是Binder Client和Binder Server通信双方。

通过上面的代码我们只能大概了解到读写操作的流程，接下来将以binder_thread_write()为例来具体分析内部的实现细节。这个函数很长，我们仍然截取关键部分逐步讲解：

```
int binder_thread_write(struct binder_proc *proc, struct binder_t
               void __user *buffer, int size, signed long *consum
{
```

在getService()这一场景下，各主要参数的值如下。

- proc

  调用者进程。

- thread

  调用者线程。

- buffer:

  即bwr. write_buffer。在talkWithDriver中，它被设置为：

```
bwr.write_buffer = (long unsigned int)mOut.data();
```

因而就是writeTransactionData中对mOut写入的数据，主要有两部分：

```
mOut.writeInt32(cmd);
mOut.write(&tr, sizeof(tr));
```

其中cmd是BC_TRANSACTION，tr是一个binder_transaction_data数据结构的变量。

- size

  即bwr.write_size。

- consumed

  即bwr.write_consumed：

```
uint32_t cmd;
void __user *ptr = buffer + *consumed; //忽略已经处理过的部分
void __user *end = buffer + size; //buffer尾部
```

这里的ptr和end分别指向buffer需要处理的数据起点和终点。

应该知道的是，buffer中可以包含不止一个命令和其对应的数据，因而接下来的代码将采用循环的形式来处理所有命令：

```
while (ptr < end && thread->return_error == BR_OK) {
     if (get_user(cmd, (uint32_t __user *)ptr)) //获取一个cmd
          return -EFAULT;
     ptr += sizeof(uint32_t); /*跳过cmd所占的空间大小，
                                        这样子指针就指向下面需要处理的数
     if (_IOC_NR(cmd) < ARRAY_SIZE(binder_stats.bc)) {/*统计数
          binder_stats.bc[_IOC_NR(cmd)]++;
          proc->stats.bc[_IOC_NR(cmd)]++;
          thread->stats.bc[_IOC_NR(cmd)]++;
     }
```

这里取出的cmd为BC_TRANSACTION，我们略过其他无关代码：

```
     switch (cmd) {
     …
     case BC_TRANSACTION:
     case BC_REPLY: {
          struct binder_transaction_data tr;/*这组命令的格式为
                                              cmd| binder_tra
          if (copy_from_user(&tr, ptr, sizeof(tr))) //从用户空
               return -EFAULT;
          ptr += sizeof(tr); //跳过tr所占空间
          binder_transaction(proc, thread, &tr, cmd == BC_RE
          break;
     }
…//其他命令的处理省略
}// binder_thread_write结束
```

获取了用户空间的binder_transaction_data 结构体变量后，紧接着程序进入binder_transaction进行处理（这个函数可以说是Binder中最长的，不过也是最关键的）。值得一提的是，此函数被同时用于处理BC_TRANSACTION和BC_REPLY两种命令——理论上来讲这种杂糅的方式并不是太好，这么做可能是两者间确实有关联，部分代码也是共用的，不过易读性就比较差了：

```
static void binder_transaction(struct binder_proc *proc,
                     struct binder_thread *thread,
                     struct binder_transaction_data *tr, int repl
{
```

这个函数的入参和上面binder_thread_write基本类似，此处不再

赘述：

```
struct binder_transaction *t;
struct binder_work *tcomplete;
size_t *offp, *off_end;
struct binder_proc *target_proc;
struct binder_thread *target_thread = NULL;
struct binder_node *target_node = NULL;
struct list_head *target_list;
wait_queue_head_t *target_wait;
struct binder_transaction *in_reply_to = NULL;
struct binder_transaction_log_entry *e;
uint32_t return_error;
```

先讲解一下这个函数中涉及的几个重要变量。

- target_proc

从名称可以看出，它是目标对象所在的进程。在我们这个场景中，就是ServiceManager。而获取目标所在进程是binder_transaction的重点之一。

- target_thread

同上。

- t

表示一个transaction操作。

- tcomplete

表示一个未完成的操作。因为一个transcation通常涉及两个进程A和B，当A向B发送了请求后，B需要一段时间来执行；此时对于A来说就是一个“未完成的操作”——直到B返回结果后，Binder驱动才会再次启动A来继续执行：

```
e = binder_transaction_log_add(&binder_transaction_log);
e->call_type = reply ? 2 : !!(tr->flags & TF_ONE_WAY);
e->from_proc = proc->pid;
e->from_thread = thread->pid;
```

```
e->target_handle = tr->target.handle;
e->data_size = tr->data_size;
e->offsets_size = tr->offsets_size;
```

上面这段代码用于添加log信息，我们可以跳过。

因为这个函数要处理BC_TRANSACTION和BC_REPLY两种情况，所以必须将它们先区分开来。显然这里是BC_TRANSACTION，即reply为false：

```
if (reply) {
     …//BC_REPLY的情况，省略代码
} else {//这个分支就是BC_TRANSACTION的情况
     if (tr->target.handle) {/*handle不为0的情况*/
          struct binder_ref *ref;
          ref = binder_get_ref(proc, tr->target.handle);
          …
          target_node = ref->node;
     } else {/*handle为0，即目标为Service Manager*/
          target_node = binder_context_mgr_node;
          …
     }
```

对BC_TRANSACTION的处理分为几个步骤。上面这段代码就是第一步，即取得目标对象所对应的target_node。如果target.handle为0，代表target是Service Manager，因而可以直接使用binder_context_mgr_node这个全局变量；否则，就调用binder_get_ref来查找是否存在一个符合handle要求的node：

```
     e->to_node = target_node->debug_id;
     target_proc = target_node->proc;//目标进程
     …
     if (!(tr->flags & TF_ONE_WAY) && thread->transaction_st
          struct binder_transaction *tmp;
          tmp = thread->transaction_stack;
          …
          while (tmp) {
               if (tmp->from && tmp->from->proc == target_pr
                    target_thread = tmp->from;
               tmp = tmp->from_parent;
          }
     }
}
```

第二步，找出目标对象的target_proc和target_thread：

```
if (target_thread) {
     e->to_thread = target_thread->pid;
     target_list = &target_thread->todo;
     target_wait = &target_thread->wait;
} else {
     target_list = &target_proc->todo;
     target_wait = &target_proc->wait;
}
e->to_proc = target_proc->pid;
```

第三步，根据第二步的结果得到target_list和target_wait，分别用于表示“todo”和“wait”列表：

```
t = kzalloc(sizeof(*t), GFP_KERNEL);
…
```

第四步，生成一个binder_transaction变量（即上面代码中的t）用于描述本次要进行的transaction——最后将其加入target_thread->todo中。这样当目标对象被唤醒时，它就可以从这个队列中取出需要做的工作：

```
tcomplete = kzalloc(sizeof(*tcomplete), GFP_KERNEL);
…
```

第五步，生成一个binder_work变量（即上面代码中的tcomplete）用于说明当前调用者线程有一宗未完成的transaction——它最后会被添加到本线程的todo队列中：

```
…
if (!reply && !(tr->flags & TF_ONE_WAY))
     t->from = thread;
else
     t->from = NULL;
t->sender_euid = proc->tsk->cred->euid;
t->to_proc = target_proc;
t->to_thread = target_thread;
t->code = tr->code;
t->flags = tr->flags;
t->priority = task_nice(current);
t->buffer = binder_alloc_buf(target_proc, tr->data_size,
     tr->offsets_size, !reply && (t->flags & TF_ONE_WAY));
if (t->buffer == NULL) {
     return_error = BR_FAILED_REPLY;
     goto err_binder_alloc_buf_failed;
```

```
}
t->buffer->allow_user_free = 0;
t->buffer->debug_id = t->debug_id;
t->buffer->transaction = t;
t->buffer->target_node = target_node;
if (target_node)
     binder_inc_node(target_node, 1, 0, NULL);
```

第六步，填写binder_transaction数据。一个binder_transaction包含的信息比较多，我们结合当前场景描述其中的重点部分。

- 调用者信息

如t→from，表示这个transaction是由谁发起的。

- 目标对象信息

如t→to_proc和t→to_thread，分别表示目标所在的进程和线程。这里对应的是Service Manager。

- transaction相关信息

如t→code是面向Binder Server的请求码，getService()服务对应的是GET_SERVICE_TRANS ACTION。

t→buffer是为了完成本条transaction所申请的内存，也就是Binder驱动小节中mmap所管理的内存区域：

```
offp = (size_t *)(t→buffer→data + ALIGN(tr→data_size, sizeof

if (copy_from_user(t→buffer→data, tr→data.ptr.buffer, tr->da
     binder_user_error("binder: %d:%d got transaction with i
          "data ptr\n", proc→pid, thread→pid);
     return_error = BR_FAILED_REPLY;
     goto err_copy_data_failed;
}
if (copy_from_user(offp, tr->data.ptr.offsets, tr->offsets_s
     binder_user_error("binder: %d:%d got transaction with i
          "offsets ptr\n", proc->pid, thread->pid);
     return_error = BR_FAILED_REPLY;
     goto err_copy_data_failed;
}
if (!IS_ALIGNED(tr->offsets_size, sizeof(size_t))) {
```

```
        binder_user_error("binder: %d:%d got transaction with "
            "invalid offsets size, %zd\n",
            proc->pid, thread->pid, tr->offsets_size);
        return_error = BR_FAILED_REPLY;
        goto err_bad_offset;
    }
```

第七步，申请到t→buffer内存后，我们可以从用户空间把数据复制过来。因为t→buffer所指向的内存空间和目标对象是共享的，所以只需要一次复制就把数据从Binder Client复制到Binder Server中了。具体过程在前面小节中已经阐述过，读者如果不清楚可以回头看看。

接下来是一个很长的for循环，它用来处理数据中的binder_object对象。因为getService()是向Service Manager查询一个对象，因而这一部分代码暂时可以略过，等到Service Manager根据用户请求写入一个object时，我们再来分析：

```
    off_end = (void *)offp + tr->offsets_size;
    for (; offp < off_end; offp++) {
        …//对binder_object对象的处理，暂时略过
    }
    if (reply) {
        BUG_ON(t->buffer->async_transaction != 0);
        binder_pop_transaction(target_thread, in_reply_to);
    } else if (!(t->flags & TF_ONE_WAY)) { //在这个场景下执行此分支
        BUG_ON(t->buffer->async_transaction != 0);
        t->need_reply = 1;
        t->from_parent = thread->transaction_stack;
        thread->transaction_stack = t;
    } else {
        BUG_ON(target_node == NULL);
        BUG_ON(t->buffer->async_transaction != 1);
        if (target_node->has_async_transaction) {
            target_list = &target_node->async_todo;
            target_wait = NULL;
        } else
            target_node->has_async_transaction = 1;
    }
```

如果用户没有指定TF_ONE_WAY标志，则将这个transaction的need_reply置为1，并记录本次transaction以备后期查询：

```
    t->work.type = BINDER_WORK_TRANSACTION;
    list_add_tail(&t->work.entry, target_list);//加入目标的处理队列
```

```
    tcomplete->type = BINDER_WORK_TRANSACTION_COMPLETE;
    list_add_tail(&tcomplete->entry, &thread->todo);//当前线程有一
    if (target_wait)
        wake_up_interruptible(target_wait);//唤醒目标
    return;
```

关键的一步来了，如我们之前所述——t最终会被加入对方的todo队列中，tcomplete被加入调用者自己的todo队列中，然后开始唤醒目标对象（如果需要的话），即Service Manager：

```
err_get_unused_fd_failed:
err_fget_failed:
err_fd_not_allowed:
err_binder_get_ref_for_node_failed:
err_binder_get_ref_failed:
err_binder_new_node_failed:
err_bad_object_type:
err_bad_offset:
err_copy_data_failed:
    …//错误处理，代码省略
}//binder_transaction结束
```

Service Manager被唤醒后，系统就要分两条路进行。

1．Service Manager被唤醒后，Binder Client端的处理

一方面，调用者Binder Client在执行完binder_transaction后，首先返回binder_thread_write，因为这个函数已经没有什么可以做的了，就直接返回到binder_ioctl。此时binder_ioctl已经执行完用户的write请求，紧接着就要判断用户是否还有read请求。为了方便阅读，我们把这段代码单独列出。如下所示：

```
        if (bwr.read_size > 0) {
            ret = binder_thread_read(proc, thread, (void __user
            bwr.read_size, &bwr.read_consumed, filp->f_flags &
            if (!list_empty(&proc->todo))
                wake_up_interruptible(&proc->wait);
            if (ret < 0) {
                if (copy_to_user(ubuf, &bwr, sizeof(bwr)))
                    ret = -EFAULT;
                goto err;
            }
        }
        if (copy_to_user(ubuf, &bwr, sizeof(bwr))) {
```

```
        ret = -EFAULT;
        goto err;
    }
```

和write请求类似，用户通过设置read_size来表示他希望读取的数据以及数据量大小。接着程序调用binder_thread_read来执行具体的读取过程。对于这个函数的分析和binder_thread_write大致相同，因而我们只挑选部分重点来讲解。如下所示：

```
static int binder_thread_read(struct binder_proc *proc,
                     struct binder_thread *thread,
                     void  __user *buffer, int size,
                     signed long *consumed, int non_block)
{
```

首先来看看函数的几个入参。其中proc和thread分别是调用者的进程和线程。参数buffer很明显是调用者提供的写入空间，也就是IPCThreadState中的mIn数据存储空间。其后的size是要读取的最大数据量，也就是mIn的容量。而consumed对应mIn.read_consumed=0：

```
    void __user *ptr = buffer + *consumed;
    void __user *end = buffer + size;

    int ret = 0;
    int wait_for_proc_work;
    if (*consumed == 0) {
        if (put_user(BR_NOOP, (uint32_t __user *)ptr))
            return -EFAULT;
        ptr += sizeof(uint32_t);
    }
```

和binder_thread_write类似，ptr和end分别指向数据的起始和终点。如果read_consumed=0，则写入一个BR_NOOP：

```
    …
    while (1) {
        uint32_t cmd;
        struct binder_transaction_data tr;
        struct binder_work *w;
        struct binder_transaction *t = NULL;

        if (!list_empty(&thread->todo))//todo列表是否为空
            w = list_first_entry(&thread->todo, struct binder_
        else if (!list_empty(&proc->todo) && wait_for_proc_work
```

```
            w = list_first_entry(&proc->todo, struct binder_wo
        else {
            if (ptr - buffer == 4 && !(thread->looper &BINDER_
                goto retry;
            break;
        }
```

在前面的binder_thread_write中，我们把一个binder_work添加到thread→todo队列中，因而这里的w不会为空，类型为BINDER_WORK_TRANSACTION_COMPLETE：

```
        if (end - ptr < sizeof(tr) + 4)
            break;

        switch (w->type) {…
        case BINDER_WORK_TRANSACTION_COMPLETE: {
            cmd = BR_TRANSACTION_COMPLETE;
            if (put_user(cmd, (uint32_t __user *)ptr))//写入上述
                return -EFAULT;
            ptr += sizeof(uint32_t);

            binder_stat_br(proc, thread, cmd);//统计信息
            list_del(&w->entry);
            kfree(w);
            binder_stats_deleted(BINDER_STAT_TRANSACTION_COMPL
        } break;
        …//省略其他无关case
    }//while循环结束
    …
    return 0;
}//binder_thread_read结束
```

可见在对BINDER_WORK_TRANSACTION_COMPLETE的处理中，程序又写入了一个BR_TRANSACTION_COMPLETE，后面可以重点看看IPCThreadState是如何处理的。

总的来说，binder_thread_read读取了两个命令，即BR_NOOP和BR_TRANSACTION_COMPLETE。完成以后仍旧回到binder_ioctl，继而返回IPCThreadState中的talkWithDriver。前面已经分析过，如果write_consumed和read_consumed都大于0，那么mOut和mIn会做出相应的调整，最后回到waitForResponse的主循环中：

```
    while (1) {
       if ((err=talkWithDriver()) < NO_ERROR) break;//前面做了那么多
```

```
        err = mIn.errorCheck();/*错误检查*/
        if (err < NO_ERROR) break;/*数据有错误*/
        if (mIn.dataAvail() == 0) continue;/*如果没有可用数据，进入下一
```

我们在源码中已经绕了一个大圈，但实际上都只是围绕talkWithDriver展开的。当函数返回时，说明mIn已有数据，我们就接着之前的代码看下具体是如何处理的：

```
        cmd = mIn.readInt32();//读取cmd
        switch (cmd) {
        case BR_TRANSACTION_COMPLETE:
            if (!reply && !acquireResult) goto finish;
            break;
          …
         default:
            err = executeCommand(cmd);
            if (err != NO_ERROR) goto finish;
            break;
        }
```

这个switch分支并没有专门针对BR_NOOP的case，因而它会进入default中，继而执行executeCommand。不过实际上什么也不做：

```
status_t IPCThreadState::executeCommand(int32_t cmd)
{    …
     switch (cmd) {
     case BR_NOOP:
         break;
     }
}
```

执行完BR_NOOP后，因为没有跳出while主循环，还会再进入一次talkWithDriver。不过因为此时mIn中还有其他数据没读完，mIn.dataPosition() < mIn.dataSize()，所以read_size和write_size都为0，也就不会调用ioctl了。

接着程序处理BR_TRANSACTION_COMPLETE，分为两种情况。假如是同步就需要继续执行主循环，即前面while(1)中的内容；否则，就直接跳转到finish结束整个操作。这里是第一种情况，即程序还会再次调用talkWithDriver与Binder驱动进行交互。

第二次进入talkWithDriver，稍微有点变化的是bwr.write_size=0，而bwr.read_size还是大于0。所以在binder_ioctl

中，就不需要执行binder_thread_write了，可直接进入binder_thread_read中。因为这个函数之前已经分析过，下面只重点列出有区别的地方：

```
static int binder_thread_read(struct binder_proc *proc, struct bi
                   void  __user *buffer, int size, signed long *c
{
     void __user *ptr = buffer + *consumed;
     void __user *end = buffer + size;

     int ret = 0;
     int wait_for_proc_work;

     if (*consumed == 0) {
          if (put_user(BR_NOOP, (uint32_t __user *)ptr))
               return -EFAULT;
          ptr += sizeof(uint32_t);
     }

retry:
     wait_for_proc_work = thread->transaction_stack == NULL &&lis
     …
```

首先还是放入一个BR_NOOP，然后判断是否要wait_for_proc_work。由于thread->transaction_stack到目前为止还不为空，而且前一次操作已经处理了todo队列，所以调用者唯一能做的就是等待Service Manager的结果。因而，它最终将通过如下语句进入睡眠等待：

```
     if (wait_for_proc_work) {//wait_for_proc_work为false
          …
     } else {
          if (non_block) { //non_block为false
               if (!binder_has_thread_work(thread))
                    ret = -EAGAIN;
          } else
               ret = wait_event_freezable(thread->wait, binder_ha
     /*进入等待，直到Service Manager来唤醒*/
     }
```

这样我们就分析完调用者这边在唤醒Service Manager后的工作了——它将最终进入等待。

2．Service Manager被唤醒后的操作

要回答这个问题，首先得知道SM在睡眠前执行到了哪里。根据前几个小节对SM的讲解，它在启动后首先进行了一系列的初始化操作，然后通知Binder驱动它即将进入循环状态，最后通过一个for语句不断解析客户端的请求。如下所示：

```
    for (;;) {
        bwr.read_size = sizeof(readbuf);
        bwr.read_consumed = 0;
        bwr.read_buffer = (unsigned) readbuf;

        res = ioctl(bs->fd, BINDER_WRITE_READ, &bwr);//向Binder驱动
        …
        res = binder_parse(bs, 0, readbuf, bwr.read_consumed, fun
        …
    }
```

由以上代码段可知，除非发生意外错误，否则SM将一直在这个for循环中响应Binder Client的请求。这个主循环一开始设置了bwr.read_size = sizeof(readbuf)，即read_size>0，而write_size=0。因而进入binder_ioctl后，只会执行binder_thread_read，此时又会发生什么情况呢？

```
static int binder_thread_read(struct binder_proc *proc, struct bi
                    void  __user *buffer, int size, signed long *
{
     …//无关部分一律省略
retry:
     wait_for_proc_work = thread->transaction_stack == NULL &&lis
```

和前面调用者进程遇到的情况一样，后面这两个条件都成立，wait_for_proc_work就为true。所以：

```
     if (wait_for_proc_work) {
          …
          if (non_block) {
               if (!binder_has_proc_work(proc, thread))
                    ret = -EAGAIN;
          } else
               ret = wait_event_freezable_exclusive (proc->wait,
                                                    binder_has_proc_work
     } else {
          …
     }
```

也就是说，SM将通过wait_event_freezable_exclusive进入睡眠等待，直到有人唤醒它。

这样我们就知道SM需要从哪一步开始执行了。它醒来后首先会检查自己的todo队列是否有需要处理的事项——根据前面的分析，此时这个队列放的是Binder Client提交的getService()的请求。如下所示：

```
while (1) {
          …
          struct binder_work *w;
          …
          switch (w->type) {
          case BINDER_WORK_TRANSACTION: {//需要处理这个业务
               t = container_of(w, struct binder_transaction, wor
          } break;
          …
}
```

业务的类型为BINDER_WORK_TRANSACTION。处理过程并不复杂，主要是把用户的请求复制到Service Manager中并对各种队列进行调整。有兴趣的读者可以自己分析。

通过binder_ioctl读取到getService()请求后，SM将调用binder_parse进行解析，最后再次调用ioctl与驱动交互，如下所示：

```
     /*frameworks/native/cmds/servicemanager/Binder.c*/
     res = ioctl(bs->fd, BINDER_WRITE_READ, &bwr);/*SM醒来后首先读取
                                               然后返回到这里*/
     res = binder_parse(bs, 0, readbuf, bwr.read_consumed, func);
                                                          getSe
```

ServiceManager中的binder_parse函数前面已经介绍过，这里结合getService()这个场景再分析一次：

```
/*frameworks/native/cmds/servicemanager/Binder.c*/
int binder_parse(struct binder_state *bs, struct binder_io *bio,
{
    int r = 1;
    uint32_t *end = ptr + (size / 4);/*数据终点*/

    while (ptr < end) {
        uint32_t cmd = *ptr++;//取出cmd
        switch(cmd) {
```

```
        …//忽略其他无关case
        case BR_TRANSACTION: {
            struct binder_txn *txn = (void *) ptr;
            binder_dump_txn(txn);//dump调试
            if (func) {
                unsigned rdata[256/4];
                struct binder_io  msg;
                struct binder_io  reply; //注意reply变量的数据类型
                int res;

                bio_init(&reply, rdata, sizeof(rdata), 4); //为rep
                bio_init_from_txn(&msg, txn);
                res = func(bs, txn, &msg, &reply); //由svcmgr_hand
                binder_send_reply(bs, &reply, txn->data, res); //
            }
            ptr += sizeof(*txn) / sizeof(uint32_t);
            break;
        }
    return r;
}
```

上面这段代码分为以下步骤来处理BR_TRANSACTION：

- 初始化reply；
- 通过func函数，即svcmgr_handler来具体处理用户请求；
- 将处理结果通过Binder驱动返回给发送请求的客户端。

特别说明一下，reply是一个binder_io变量，这是Service Manager内部的一种数据类型。其主要的内部成员释义如下：

```
struct binder_io
{
    char *data;            /* 数据区当前地址 */
    uint32_t *offs;        /* offset区当前地址 */
    uint32_t data_avail;   /* 数据区剩余空间 */
    uint32_t offs_avail;   /* offset区剩余空间 */

    char *data0;           /* 数据区起始地址 */
    uint32_t *offs0;       /* offset区起始地址 */
    uint32_t flags;
    uint32_t unused;
};
```

这几个成员变量的取名确实不太合理，严重影响了大脑运转。记

住，它其实是划分了两个区域，即data区和offs区；而每个区又分别有个起始地址和当前地址。所以，一共有data、data0、offs和offs0共4个地址指针。

先来看看如何初始化reply：

```
void bio_init(struct binder_io *bio, void *data,uint32_t maxdata,
{
    uint32_t n = maxoffs * sizeof(uint32_t); //最大可偏移4个，共16字

    if (n > maxdata) { //maxdata为256
        bio->flags = BIO_F_OVERFLOW;
        bio->data_avail = 0;
        bio->offs_avail = 0;
        return;
    }

    bio->data = bio->data0 = (char *) data + n;
    bio->offs = bio->offs0 = data;
    bio->data_avail = maxdata - n;
    bio->offs_avail = maxoffs; //注意它的起始值是4，不是16
    bio->flags = 0;
}
```

和Parcel相比较，我们可以得出初步的结论：binder_io是Service Manager内部用于存储binder object的一种数据结构。

接着程序调用res = func(bs, txn, &msg, &reply)来处理，而func已经被注册为svcmgr_handler。这些知识在前面几个小节都已经分析过，下面再复习一下：

```
    switch(txn->code) {
    case SVC_MGR_GET_SERVICE:
    case SVC_MGR_CHECK_SERVICE:
        s = bio_get_string16(msg, &len);
        ptr = do_find_service(bs, s, len, txn->sender_euid);/*查找
        if (!ptr)
            break;
        bio_put_ref(reply, ptr);/*将结果存入reply中*/
```

在svcmgr_handler中，针对getService请求（SVC_MGR_GET_SERVICE），首先调用do_find_service进行查找：如果顺利的话就会返回一个void*类型的ptr，这就是最后要转化成IBinder

的那个指针。然后把这个指针写入reply中，即上面的binder_io变量。

读者可能会有这样的疑问：ptr是个什么值呢？要回答这个问题，就要看addService时在Service Manger中存入了什么。在SM中添加一个Service的过程和getService非常类似，重复的部分不再赘述，直接来看看Service Manager对SVC_MGR_ADD_SERVICE的处理：

```
    case SVC_MGR_ADD_SERVICE:
       s = bio_get_string16(msg, &len);
       ptr = bio_get_ref(msg);
       allow_isolated = bio_get_uint32(msg) ? 1 : 0;
       if (do_add_service(bs, s, len, ptr, txn->sender_euid, allo
           return -1;
       break;
```

可见，ptr这个值是在bio_get_ref中获得的：

```
void *bio_get_ref(struct binder_io *bio)
{
    struct binder_object *obj;
    obj = _bio_get_obj(bio);
    …
    if (obj->type == BINDER_TYPE_HANDLE)
        return obj->pointer;

    return 0;
}
```

简要说下这个函数的逻辑：它根据用户传进来的binder_object的类型，即obj→type来为前面的ptr赋值。Binder中共有以下几种object类型，在Binder.h中定义：

```
enum {
 BINDER_TYPE_BINDER = B_PACK_CHARS('s', 'b', '*', B_TYPE_LARGE),
 BINDER_TYPE_WEAK_BINDER = B_PACK_CHARS('w', 'b', '*', B_TYPE_LAR
 BINDER_TYPE_HANDLE = B_PACK_CHARS('s', 'h', '*', B_TYPE_LARGE),
 BINDER_TYPE_WEAK_HANDLE = B_PACK_CHARS('w', 'h', '*', B_TYPE_LAR
 BINDER_TYPE_FD = B_PACK_CHARS('f', 'd', '*', B_TYPE_LARGE),
};
```

其中前两种只能是针对Binder Client和Binder Server在同一个进程中的情况，而后两种因为传递的是Binder句柄也就没有任何限制了。比如，A知道一家著名餐馆的电话号码，之后把它给了B，那么B就可以

在任何时候凭借这个电话号码与餐馆建立联系了。

一个Binder Client调用ServiceManager.addService将自己添加到Service Manager时，实际上一开始这个object的类型是BINDER_TYPE_BINDER；不过到了Binder驱动中，这个值就变成了BINDER_TYPE_HANDLE。或者也可以这样理解：BINDER_TYPE_BINDER代表的是内存地址，所以直接发送给另一个进程并没有实际的意义；而BINDER_TYPE_HANDLE是这个object在Binder驱动中的id号——通过这个号码最终可以找到对应的目标Client/Server。Binder驱动负责对它们进行转换，代码如下所示。

```
static void binder_transaction(struct binder_proc *proc,struct bi
                      struct binder_transaction_data *tr, int rep
{
          …
          switch (fp->type) {
          case BINDER_TYPE_BINDER:
          case BINDER_TYPE_WEAK_BINDER: {
               …
               if (fp->type == BINDER_TYPE_BINDER)
                    fp->type = BINDER_TYPE_HANDLE;//类型变了
               else
                    fp->type = BINDER_TYPE_WEAK_HANDLE;
               fp->handle = ref->desc;//值也相应的产生了变化
            …
}
```

因而bio_get_ref产生的对象最终的类型是BINDER_TYPE_HANDLE，ptr就是Binder的句柄值。

得到这个句柄值后，我们需要把它写入回复中：

```
bio_put_ref(reply, ptr);
```

由之前对reply的初始化操作可知，reply中的offset区域得到16字节的空间，其余为data区域。回到bio_put_ref中看看对reply做了什么操作：

```
void bio_put_ref(struct binder_io *bio, void *ptr)//这个函数的bio参
{
    struct binder_object *obj;

    if (ptr)
```

```
        obj = bio_alloc_obj(bio); //ptr是之前SM查表得到的服务对应的句桁
    else
        obj = bio_alloc(bio, sizeof(*obj));
     …
    obj->flags = 0x7f | FLAT_BINDER_FLAG_ACCEPTS_FDS;
    obj->type = BINDER_TYPE_HANDLE; //注意这个类型，后面还会遇到
    obj->pointer = ptr; //将ptr保存到obj中
    obj->cookie = 0;
}
```

这个函数没有返回值，因而可以猜想到新创建的obj一定会与reply有直接的关系。答案可以从下面这个函数中找到：

```
static struct binder_object *bio_alloc_obj(struct binder_io *bio)
{
    struct binder_object *obj;
    obj = bio_alloc(bio, sizeof(*obj));//确定obj的具体地址
    if (obj && bio->offs_avail) {
        bio->offs_avail--; //个数减一
        *bio->offs++ = ((char*) obj) - ((char*) bio->data0);/*原来
                        data区域的写入大小的，这是“可变长度数据”的一种存
        return obj;
    }

    bio->flags |= BIO_F_OVERFLOW;
    return 0;
}
```

上面代码段中的bio_alloc和上面分析过的writeInplace作用类似，即确定将要写入数据的起始和结束位置，同样以4对齐，所以obj就指向可以写入的数据区起始位置（这个位置是在reply的data区域中的）。这意味着对obj写入数据，实际上就是写入reply的data区域中。

到这里基本上就清楚了，reply存入了一个binder_object数据结构，类型为BINDER_TYPE_HANDLE。而binder_objcet.pointer中是SM查找到的Service的指针（将最终被转换成Ibinder）。

一切准备就绪后，SM便要将结果发送给Binder驱动。可想而知，数据格式必须遵守Binder协议的规定，因而填充过程很重要：

```
void binder_send_reply(struct binder_state *bs,struct binder_io *
{
    struct {
        uint32_t cmd_free;
```

```
        void *buffer;
        uint32_t cmd_reply;
        struct binder_txn txn;//对应Binder驱动中的binder_transactio
    } __attribute__((packed)) data;

    data.cmd_free = BC_FREE_BUFFER;
    data.buffer = buffer_to_free;
    data.cmd_reply = BC_REPLY; //注意这里的命令类型
    data.txn.target = 0;
    data.txn.cookie = 0;
    data.txn.code = 0;
    if (status) {
     …//省略，status用于指示之前操作有没有error
    } else {//没有error的情况
          data.txn.flags = 0;
          data.txn.data_size = reply->data - reply->data0;
          data.txn.offs_size = ((char*) reply->offs) - ((char*) r
          data.txn.data = reply->data0; //reply中数据区起始地址
          data.txn.offs = reply->offs0; //offset区起始地址
    }
    binder_write(bs, &data, sizeof(data));//写入Binder驱动
}
```

这个函数里又定义了一个数据结构data，其中最重要的变量是txn。可以看到，txn中保存了reply中的数据和offset区的起始地址：

```
int binder_write(struct binder_state *bs, void *data, unsigned le
{
    struct binder_write_read bwr;
    int res;
    bwr.write_size = len;
    bwr.write_consumed = 0;
    bwr.write_buffer = (unsigned) data; //将data传入到bwr中
    bwr.read_size = 0;//不读取数据，只写入
    bwr.read_consumed = 0;
    bwr.read_buffer = 0;
    res = ioctl(bs->fd, BINDER_WRITE_READ, &bwr); //与Binder驱动交
    …
    return res;
}
```

这个函数中有两个重要步骤。

- 将相关数据填入binder_write_read。不管之前SM定义了多少内部数据结构，它与Binder驱动交互就得遵守后者的数据规范，包括

binder_write_read和binder_txn等。

- 调用ioctl将命令发送给Binder Driver。

然后就进入binder_ioctl→binder_thread_write→binder_transaction进行处理，这和我们之前分析的情况基本大同小异，因而下面只列出不同的部分。

首先会进入binder_thread_write，命令类型为BC_REPLY。由以前的分析可知，它和BC_TRANSACTION一样都是在binder_transaction中处理的：

```
static void binder_transaction(struct binder_proc *proc, struct b
                      struct binder_transaction_data *tr, int rep
{
     …//这些变量和之前的分析是完全一致的，不再赘述
     if (reply) {//BC_REPLY的情况
          in_reply_to = thread->transaction_stack;//找到要“reply”给
          …
          thread->transaction_stack = in_reply_to->to_parent;
          target_thread = in_reply_to->from;//目标对象所在线程
          …
          target_proc = target_thread->proc;//目标对象所在进程
     } else {//BC_TRANSACTION的情况
          …
     }
```

和BC_TRANSACTION同理，BC_REPLY显然也要先找到目标进程/线程，即谁发起了这个transaction。根据之前的分析，Service Manager会在thread->transaction_stack中保存这一信息，因而就有根可寻了。如下：

```
in_reply_to = thread->transaction_stack;
```

有了这个基础，其他的就都好办了：

```
target_thread = in_reply_to->from;
target_proc = target_thread->proc;
     if (target_thread) {
          e->to_thread = target_thread->pid;
          target_list = &target_thread->todo;
          target_wait = &target_thread->wait;
     } else {
```

```
        target_list = &target_proc->todo;
        target_wait = &target_proc->wait;
    }
```

紧接着找出目标的target_list和target_wait，这在后面都要用到：

```
    /* TODO: reuse incoming transaction for reply */
    t = kzalloc(sizeof(*t), GFP_KERNEL);
    …
    tcomplete = kzalloc(sizeof(*tcomplete), GFP_KERNEL);
    …
```

还是和BC_TRANSACTION类似，BC_REPLY也生成了t和tcomplete。其中t是给目标对象的，而tcomplete是给命令发起者自己的。只不过这里的目标和命令发起者与之前相反——目标对象是Binder Client，BC_REPLY的发起者是Service Manager：

```
    if (!reply && !(tr->flags & TF_ONE_WAY))
        t->from = thread;
    else
        t->from = NULL;
    …//给变量t赋值过程省略(和BC_TRANSACTION完全一样)
    if (copy_from_user(t->buffer->data, tr->data.ptr.buffer, tr-
            /*从ServiceManager进程空间复制数据*/
        …
    }
    if (copy_from_user(offp, tr->data.ptr.offsets, tr->offsets_s
        …
    }
    …
```

上面这段代码主要给t赋值，和BC_TRANSACTION完全一样，读者可以看看。不过因为Service Manager这次带了一个binder_object，所以接下来要对这个object进行必要的处理（即之前讲解过的BINDER_TYPE_HANDLE和BINDER_TYPE_BINDER之间的转换）。如下所示：

```
    off_end = (void *)offp + tr->offsets_size;/*offset区域的结束地
    for (; offp < off_end; offp++) {/*object可能不只一个*/
        struct flat_binder_object *fp;
        …
        fp = (struct flat_binder_object *)(t->buffer->data + *o
        switch (fp->type) {
        …
```

```
        case BINDER_TYPE_HANDLE:
        case BINDER_TYPE_WEAK_HANDLE: {//如果这个object的类型是HAN
             struct binder_ref *ref = binder_get_ref(proc, fp->
             …
             if (ref->node->proc == target_proc) {//目标进程和obj
                  if (fp->type == BINDER_TYPE_HANDLE)
                       fp->type = BINDER_TYPE_BINDER;//直接可以使
                  else
                       fp->type = BINDER_TYPE_WEAK_BINDER;
                  fp->binder = ref->node->ptr;
                  fp->cookie = ref->node->cookie;
                  binder_inc_node(ref->node, fp->type == BINDER
                                                 0, NULL);
                  …
             } else {/*object不在目标进程的范围*/
                  struct binder_ref *new_ref;
                  new_ref = binder_get_ref_for_node(target_proc
                  …
                  fp->handle = new_ref->desc;
                  binder_inc_ref(new_ref, fp->type == BINDER_TY
                  …
             }
        } break;
        …
        default:
             …//出错处理
        }
   }
```

上面代码段只保留BINDER_TYPE_HANDLE的处理，因为这是Service Manager传过来的Binder Object的类型（见Service Manager中的bio_put_ref）。可以看到，这里主要对最终会传递给调用者的Binder Object进行了一次转换。

- binder_get_ref

通过handle值查找与此binder object相关联的binder_ref，这个是调用addService服务时创建的。

- 调用getService服务的进程和Binder Object所属进程是不是同一个?

正如我们一直强调的，不同进程间的内存空间是没有办法直接相互访问的；反之，如果它们属于同一个进程空间，那么就可以直接将Binder Object的内存地址传给调用者；否则，调用者就只能通过

handle值来与对方通信了。

因为一般情况下ref->node->proc不会等于target_proc，所以程序走的是上述代码段的else分支。大家可以根据上面的分析进行理解：

```
     if (reply) {
          BUG_ON(t->buffer->async_transaction != 0);
          binder_pop_transaction(target_thread, in_reply_to);
     } else if (!(t->flags & TF_ONE_WAY)) {
          …
     } else {
          …
     }
     t->work.type = BINDER_WORK_TRANSACTION;//业务类型
     list_add_tail(&t->work.entry, target_list);//添加到目标进程的tc
     tcomplete->type = BINDER_WORK_TRANSACTION_COMPLETE;
     list_add_tail(&tcomplete->entry, &thread->todo);//添加一个"未
     if (target_wait)
          wake_up_interruptible(target_wait);//唤醒目标进程
     return;
    …
}
```

一切准备就绪后，就要唤醒目标进程了。还记得吗？当时getService的调用者Binder Client在经过一系列的函数调用后，即：waitForResponse(IPCThreadState)→talkWithDriver(IPCThreadState)→binder_ioctl(Binder.c)→binder_thread_read(Binder.c)，就进入睡眠等待了——此时它发起的服务请求已经有回复了，所以就需要重新唤醒起它来接收结果。

而Service Manager的队列中也加入了一个类型为BINDER_WORK_TRANSACTION_COMPLETE的tcomplete，因而它首先会通过binder_thread_read读取并处理这个事项，然后在第二次的binder_thread_read中再次进入睡眠等待，直到有Binder Client向它发起新的服务请求。

下面看看当调用者被唤醒后的操作。前面已经分析过，这时Binder Client是在binder_thread_read中睡眠的。具体是：

```
ret = wait_event_freezable (thread->wait, binder_has_thread_work(
```

我们接着这条语句往下走：

```
…
while (1) {
     uint32_t cmd;
     struct binder_transaction_data tr;
     struct binder_work *w;
     struct binder_transaction *t = NULL;

     if (!list_empty(&thread->todo))//todo list中有可处理事项
          w = list_first_entry(&thread->todo, struct binder_
     else if (!list_empty(&proc->todo) && wait_for_proc_work
          w = list_first_entry(&proc->todo, struct binder_wo
     else {…
     }
```

前面Service Manager在thread->todo队列中插入了一个工作事项，这里就通过w把它取出来：

```
     if (end - ptr < sizeof(tr) + 4)
          break;
     switch (w->type) {
     case BINDER_WORK_TRANSACTION: {
          t = container_of(w, struct binder_transaction, wor
     } break;
     }
```

这个binder_work的类型是BINDER_WORK_TRANSACTION，通过w在binder_transaction中的位置取得t：

```
     …
     if (t->buffer->target_node) {
          struct binder_node *target_node = t->buffer->targe
          tr.target.ptr = target_node->ptr;
          tr.cookie =  target_node->cookie;
          …
          cmd = BR_TRANSACTION;//注意业务类型
     } else {
          …
     }
     tr.code = t->code;
     tr.flags = t->flags;
     tr.sender_euid = t->sender_euid;

     if (t->from) {
          struct task_struct *sender = t->from->proc->tsk;
```

```
            tr.sender_pid = task_tgid_nr_ns(sender,current->ns
        } else {
            tr.sender_pid = 0;
        }

        tr.data_size = t->buffer->data_size;//数据区域大小
        tr.offsets_size = t->buffer->offsets_size;//offset区域大
        tr.data.ptr.buffer = (void *)t->buffer->data +proc->use

        tr.data.ptr.offsets = tr.data.ptr.buffer +ALIGN(t->buff
                                                  sizeof(void *
```

上面这段代码用于准备将要发送给调用者进程的数据，其中的逻辑比较简单且大多已经讲解过，读者可以自行分析各个变量的含义：

```
        if (put_user(cmd, (uint32_t __user *)ptr))
            return -EFAULT;
        ptr += sizeof(uint32_t);
        if (copy_to_user(ptr, &tr, sizeof(tr)))//将数据复制到用户空
            return -EFAULT;
        ptr += sizeof(tr);
```

将准备好的数据复制到调用者空间中：

```
        …
        list_del(&t->work.entry);//删除t
        t->buffer->allow_user_free = 1;
        if (cmd == BR_TRANSACTION && !(t->flags & TF_ONE_WAY))
            t->to_parent = thread->transaction_stack;
            t->to_thread = thread;
            thread->transaction_stack = t;
        } else {
            …
        }
        break;
    }
```

对t的处理已经结束，因而可以把它删除；而且如果不是BR_TRANSACTION的话，就不用再保存transaction_stack。这样调用者就执行完binder_thread_read了，之后它先返回binder_ioctl，然后回到用户进程空间中的talkWithDriver。因为读取到了数据，程序还需要对mIn进行调整，之前已经多次讲解过，这里不再赘述。

最后回到waitForResponse@IPCThreadState，来看看它对BR_REPLY

的处理：

```
        case BR_REPLY:
            {
                binder_transaction_data tr;
                err = mIn.read(&tr, sizeof(tr));//读取数据

                if (err != NO_ERROR) goto finish;
                if (reply) {
                    if ((tr.flags & TF_STATUS_CODE) == 0) {
                        reply->ipcSetDataReference(reinterpret_ca
  (tr.data. ptr.buffer),tr.data_size, reinterpret_cast<const size
                                 tr.offsets_size/sizeof(size_t),
                    } else {…//错误处理
                    }
                } else {…//当reply为NULL的情况
                }
            }
          goto finish;//跳出while循环，从而结束waitForResponse
…
```

程序首先从mIn中读取到transaction的标准格式数据，即tr。我们知道reply是不为空的，且tr.flags中也不含有TF_STATUS_CODE标志，所以上面代码段中最重要的一句就是调用ipcSetData Reference对数据进行处理，它是Parcel.cpp中的一个函数：

```
void Parcel::ipcSetDataReference(const uint8_t* data, size_t data
                    const size_t* objects, size_t objectsCount, r
                             void* relCookie)
{
    freeDataNoInit();
    mError = NO_ERROR;
    mData = const_cast<uint8_t*>(data);
    mDataSize = mDataCapacity = dataSize;
    mDataPos = 0;
    ALOGV("setDataReference Setting data pos of %p to %d\n", this
    mObjects = const_cast<size_t*>(objects);
    mObjectsSize = mObjectsCapacity = objectsCount;
    mNextObjectHint = 0;
    mOwner = relFunc;
    mOwnerCookie = relCookie;
    scanForFds();
}
```

先来看看函数的几个入参：

- data；
- dataSize；
- objects；
- objectsCount。

前面两个参数分别表示数据区及它的大小，后面两个就是Binder Object区（offset区）和它的大小。在我们的场景中，Object的个数是1。

在这个例子中，调用者向Service Manager发起了getService(name)请求，因而对它而言最重要的数据就是name所对应的Binder Object——可以猜想到ipcSetDataReference这个函数必定与此有关联。它把从Binder Driver中读取的Service Manager的回复（存储在mIn中）填入reply这个Parcel中，以供后续程序读取时使用。这样整个函数的逻辑就很简单，主要是做了些赋值操作，大家可以自行阅读。

当waitForResponse处理完BR_REPLY后，就直接跳转（goto）到finish来结束整个while主循环了。之后通过层层返回，最终来到我们getService场景的发源地，即ServiceManagerProxy中的getService()中（注意，此时已经到了Java层）：

```
    mRemote.transact(GET_SERVICE_TRANSACTION, data, reply, 0);/*这
                                                              代码都是基于这个
            IBinder binder = reply.readStrongBinder();
            //执行到这里，说明已经收到Service Manager的回复了
            reply.recycle();
            data.recycle();
            return binder;
```

执行完transact后，reply中就有我们想要的查询结果了。不过流程并未结束，还需要将这一结果读取出来，并转换成Ibinder，即readStrongBinder。我们跳过此函数的中间过程，直接来分析其native层的实现：

```
sp<IBinder> Parcel::readStrongBinder() const
{
    sp<IBinder> val;
    unflatten_binder(ProcessState::self(), *this, &val);
    return val;
}
```

通常情况下，unfaltten_binder和flatten_binder是需要配套使用的，不过在此场景中Service Manager并没有直接使用Parcel，而是使用了与flatten_binder等价的其他实现：

```
status_t unflatten_binder(const sp<ProcessState>& proc,const Parc
{
    const flat_binder_object* flat = in.readObject(false); /*读取-
    if (flat) {
        switch (flat->type) {
            case BINDER_TYPE_BINDER://同进程的话是这种类型
                *out = static_cast<IBinder*>(flat->cookie);
                return finish_unflatten_binder(NULL, *flat, in);
            case BINDER_TYPE_HANDLE://不同进程的话是这种类型
                *out = proc->getStrongProxyForHandle(flat->handle
                return finish_unflatten_binder(static_cast<BpBind
        }
    }
    return BAD_TYPE;
}
```

看到flat_binder_object大家应该很熟悉吧，所有的努力都是冲这个来的。首先从reply这个Parcel中读取出flat_binder_object，然后根据类型来区分处理。关于binder type已经有过多次讲解，这里显然是属于BINDER_TYPE_HANDLE这种情况，因而就调用getStrongProxyForHandle为这个Handle生成一个Proxy(BpBinder)。这个函数之前也已经碰到过（handle为0的情况，即Service Manager），这里再来看看对于普通Binder Server会有什么不同：

```
sp<IBinder> ProcessState::getStrongProxyForHandle(int32_t handle)
{
    sp<IBinder> result;
    AutoMutex _l(mLock);

    handle_entry* e = lookupHandleLocked(handle);//先查找当前记录

    if (e != NULL) {//e通常情况不会是NULL
        IBinder* b = e->binder;
        if (b == NULL || !e->refs->attemptIncWeak(this)) {
            b = new BpBinder(handle); //无法增加引用或者b为NULL
            e->binder = b;
            if (b) e->refs = b->getWeakRefs();
            result = b;
        } else {
            result.force_set(b);
```

```
            e->refs->decWeak(this);
        }
    }
    return result;
}
```

可以看到，主体流程没有任何差异。首先查找本地是否已经有这个IBinder记录，以避免重复操作；否则就通过new BpBinder创建一个新的Proxy（即便有记录，但增加引用时失败也同样要重新创建），最重要的就是为这个新BpBinder添加handle值属性。最终返回给调用者的是一个sp指针，内部指向这个BpBinder（强制类型转换成了Ibinder）。

成功通过readStrongBinder获取到IBinder对象后，getService@ServiceManagerProxy的任务就结束了，最终ServiceManager.getService的调用者得到的就是这个对象。这样我们以ServiceManager提供的getService服务为例，完整地剖析了Binder Client获取Binder Server的全过程。

虽然本小节目标很简单（获取getService服务），但因为同时涉及了JNI、Binder驱动、Binder上层建筑等一系列处理流程，使得整个分析过程可谓“山路十八弯”，困难重重。其中的一些重点元素罗列如下：

- ServiceManagerProxy

当某个Binder Server在启动时，会把自己的名称name与对应的Binder句柄值保存在ServiceManager中。调用者通常只知道Binder Server的名称，所以必须先向Service Manager发起查询请求，就是getService(name)。

而Service Manager自身也是一个Server，就好像互联网上的DNS服务器本身也需要提供IP地址才能被访问一样。只不过这个IP地址是预先就设定好了的（句柄值为0），因而任何Binder Client都可以直接通过0这个Binder句柄创建一个BpBinder，再通过Binder驱动去获取Service Manager的服务。具体而言，就是调用BinderInternal.getContextObject()来获得Service Manager的BpBinder。

Android系统同时支持Java与C/C++层的Binder机制，因而很多对象

都必须有“双重身份”，如BpBinder在Java层以IBinder来表示。对于Service Manager而言，IBinder的真正持有者与使用者是ServiceManagerProxy——它是Service Manager在本地的代表，我们在设计小节曾以“留学服务中心”为例做过类比。

- ProcessState和IPCThreadState

大多数程序都有IPC的需要，而进程间通信本身又是非常烦琐的，因而Android系统特别为程序进程使用Binder机制封装了两个实现类，即ProcessState和IPCThreadState。从名称上可以看出，前者是进程相关的，而后者是线程相关的。ProcessState负责打开Binder驱动设备，进行mmap()等准备工作；而如何与Binder驱动进行具体的命令通信则由IPCThreadState来完成。

在getService()这个场景中，调用者是从Java层的IBinder.transact()开始，层层往下调用到IPCThreadState.transact()，然后通过waitForResponse进入主循环——直至收到Service Manager的回复后才跳出循环，并将结果再次层层回传到应用层。本小节的大部分源码内容就是在waitForResponse里展开的。

真正与Binder驱动打交道的地方是talkWithDriver中的ioctl()，整个流程中多次调用了这个函数。

- Binder驱动

在这个场景中，主要涉及了Binder驱动提供的binder_ioctl，binder_thread_write，binder_thread_read和binder_transaction等几个重要的函数实现。Binder驱动通过巧妙的机制来使数据的传递更加高效，即只需要一次复制就可以把数据从一个进程复制到另一个进程。Binder中还保存着大量的全局以及进程相关的变量，用于管理每个进程/线程的状态、内存申请和待办事项等一系列复杂的数据信息。正是这些变量的有效协作，才使得整个Binder通信真正“动”了起来。

- Service Manager的实现

ServiceManager在Android系统启动之后就运行起来了，并通过BINDER_SET_CONTEXT_MGR把自己注册成Binder“大管家”。它在做完一

系列初始化后，在最后一次ioctl的read操作中会进入睡眠等待，直到有Binder Client发起服务请求而被Binder驱动唤醒。

Service Manager唤醒后，程序分为两条主线索：其一，Service Manager端将接着执行read操作，把调用者的具体请求读取出来，然后利用binder_parse解析，再根据实际情况填写transaction信息，最后把结果通过BR_REPLY命令（也是ioctl）返回Binder驱动。

其二，发起getService请求的Binder Client在等待Service Manager回复的过程中会进入休眠，直到被Binder驱动再次唤醒——它和Service Manager一样也是在read中睡眠的，因而醒来后继续执行读取操作。这一次得到的就是Service Manager对请求的执行结果。程序先把结果填充到reply这个Parcel中，然后通过层层返回到ServiceManagerProxy，再利用Parcel.readStrongBinder生成一个BpBinder，最终经过类型转换为IBinder对象后传给调用者。

这样整个ServiceManager.getService()的流程就都分析完了。不过对于调用者来说，万里长征才刚刚开始。得到的IBinder对象要先经过asInterface做一次包装，如ServiceManager的BpBinder就被包装成了IserviceManager（实际上就是一个ServiceManagerProxy）。这么做的目的在于可以让应用程序更加方便地使用Service Manager提供的服务（其他Binder Server也类似）。这些知识点在本小节的分析过程中都已经讲解过，大家如果还有疑问，可以回头复习下。

总结整个getService的调用流程，如图6-20所示。

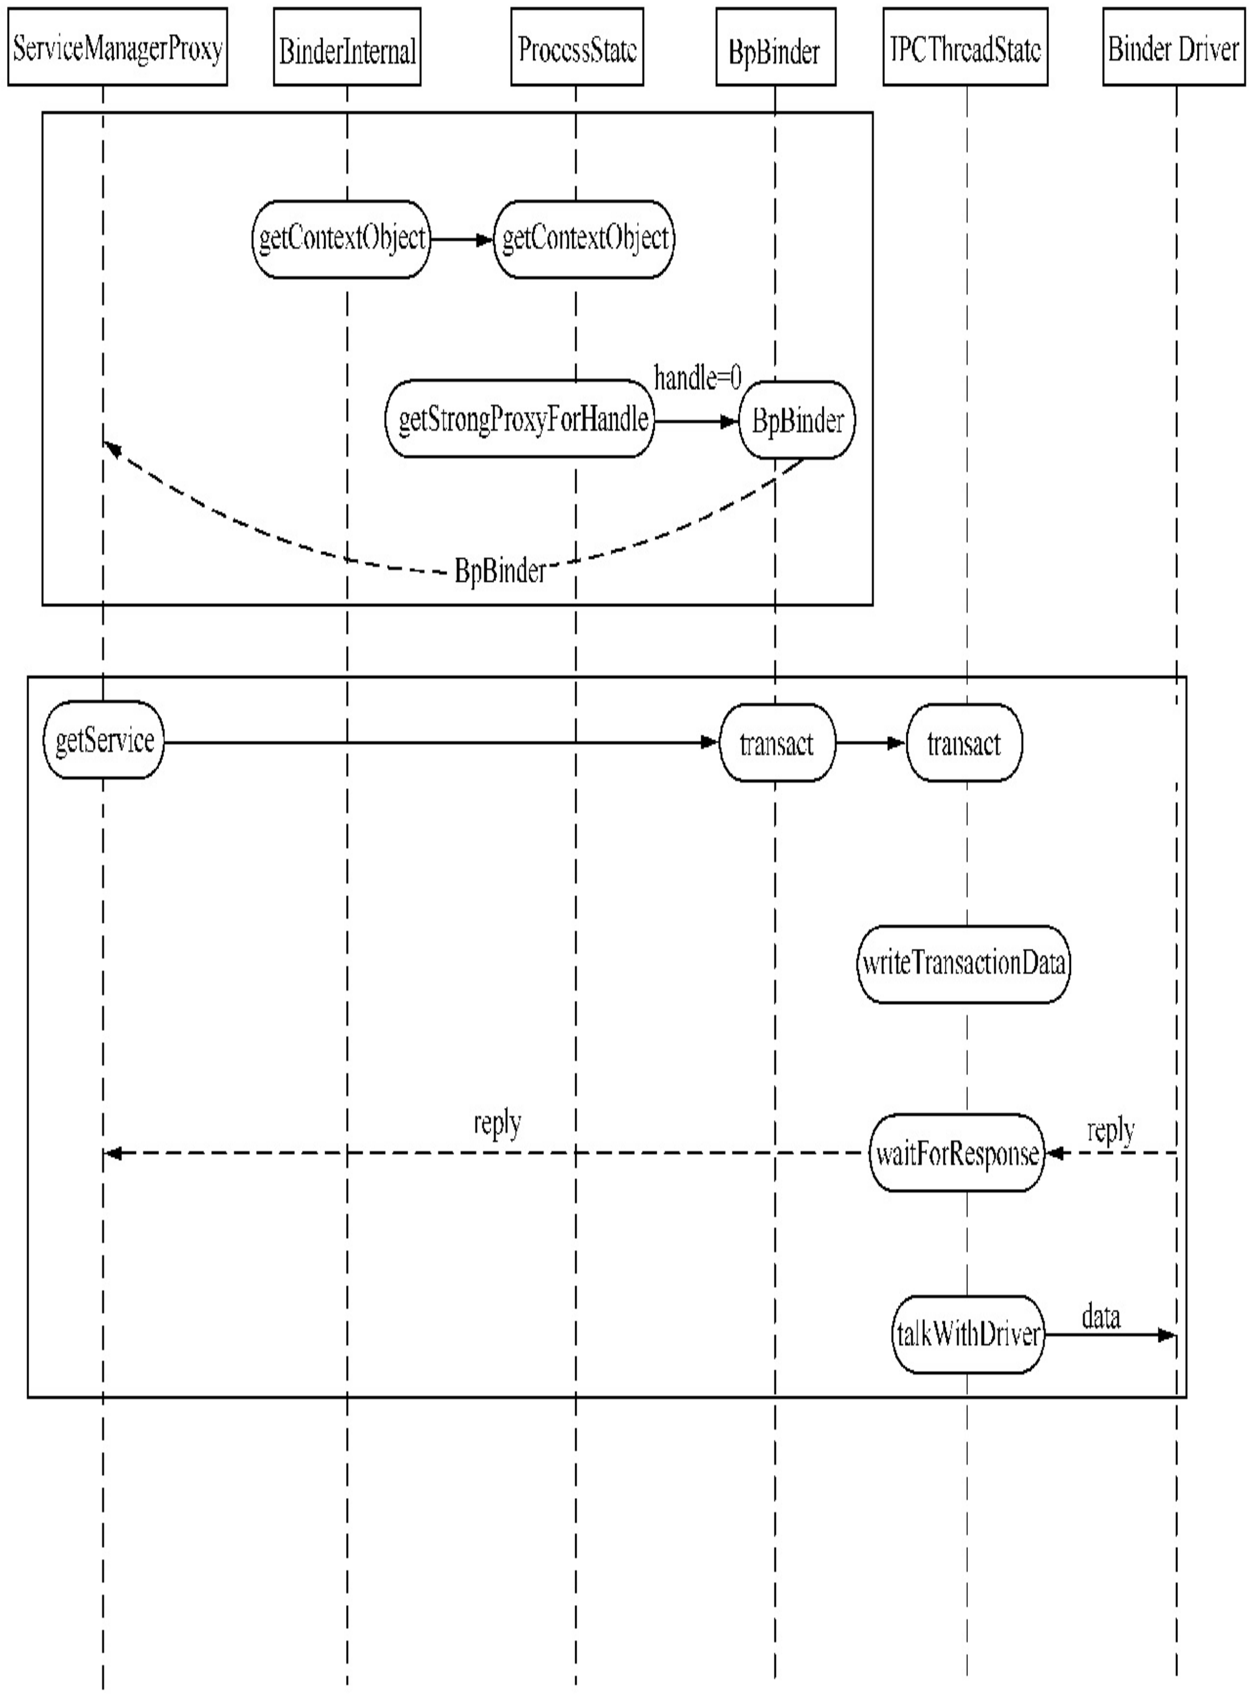
ServiceManagerProxy
BinderInternal
ProcessState
BpBinder
IPCThreadState
Binder Driver
getContextObject
getContextObject
getStrongProxyForHandle
handle=0
BpBinder
BpBinder
getService
transact
transact
writeTransactionData
reply
waitForResponse
reply
talkWithDriver
data

▲图6-20　getService调用流程图

图6-20分为两部分，上半部分是获取IBinder（BpBinder，BinderProxy）的过程（实际上其中还涉及ServiceManager.java和ServiceManagerNative.java。为了避免发生混乱，我们是从ServiceManagerProxy开始讲解的，因而和代码中的实现有略微差别，不过不影响整体），下半部分是getService的执行过程。

本小节结合Service Manager给大家详细讲解了Binder Client和它获取Binder Server服务的全过程。Service Manager作为Binder Server有其“特殊性”——而正是借助于这种特殊性我们才能更简洁明了地勾勒出“Binder框架”，从而也为下一小节分析更具典型意义的Binder Client打下坚实的基础。

6.5 Binder客户端——Binder Client

大家对“Binder”这个词可能会比较陌生，不过提起诸如bindService这样的接口方法，相信大家就会有共鸣了——顾名思义，这个函数是希望“绑定某项服务”。而之所以称为“绑定”，是因为发起请求的应用程序和目标服务程序原本并没有任何直接联系，它们都是独立运行的个体。换句话说，它们之间的连接属于进程间的通信，因而需要一种可以把两者“绑定”在一起的机制——Binder。

本小节将从应用开发者的角度来理解Binder机制，特别是Binder Client。

大家先来做个发散练习，把头脑中与Binder和应用开发有关的记忆充分挖掘出来，然后把它们“串”起来。

1．Binder是什么

它是众多进程间通信的一种。进程间通信是每个操作系统都需要提供的，我们在操作系统基础章节学习到了多种IPC；并且通过本章前面几小节的讲解，相信大家对Binder的实现原理也有了更深的认识，如图6-21所示。

2．应用程序与Binder

Binder的最大“消费者”是Java层的应用程序。图6-21虽然简单，却概括了Binder的实质，即它是进程间的通信桥梁。接下来我们还需要沿着这条线索继续挖掘。图中所示的进程1是一种泛指，那么一个进程需要满足什么条件，或者说要做哪些准备工作才有资格使用Binder呢？从应用开发人员的角度来看，这似乎并不在他们的考虑范围，因为一般情况下他们可以在程序代码的任何位置通过bindService，startActivity以及sendBroadcast等一系列接口方法来实现与其他进程的交互，如图6-22所示。

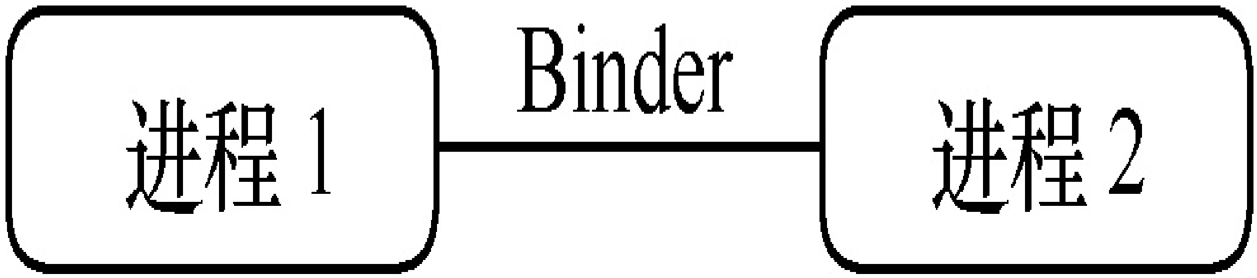

▲图6-21　Binder是什么

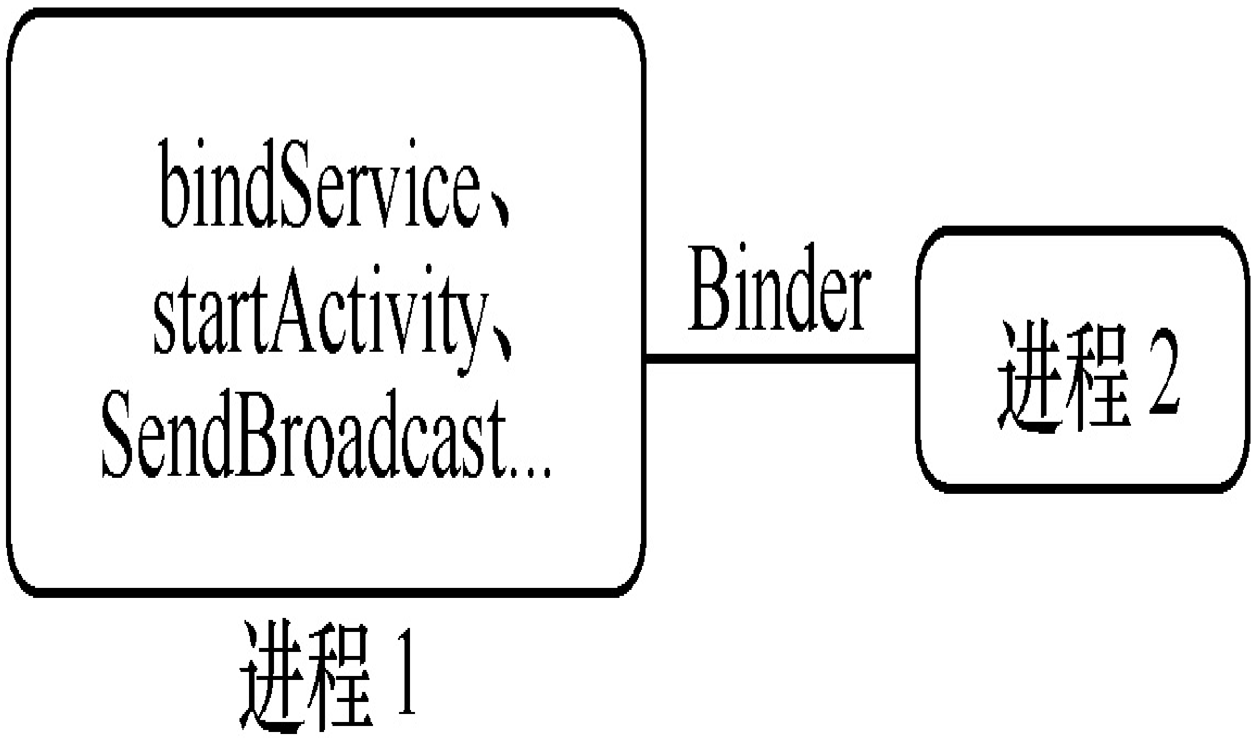

▲图6-22　从应用开发人员的使用角度看Binder

有了Binder Driver，Service Manager的努力，以及Android系统专门面向应用开发提供的Binder强有力的封装，才能使应用程序之间顺利地进行无缝通信。我们从四大组件中就可以看出一些端倪。

- Activity

  通过startActivity可以启动目标进程。

- Service

任何应用程序都可以通过startService或bindService来启动特定的服务，而不论后者是不是跨进程的。

顺便提一下，这两种启动方式的区别主要体现在它们的生命周期上，如图6-23所示。

- Broadcast

任何应用程序都可以通过sendBroadcast来发送一个广播，且无论广播处理者是不是在同一个进程中。

- intent

四大组件的上述操作中，多数情况下并不会特别指明需要由哪个目标应用程序来响应请求——它们会先通过一个被称为“intent”的对象表达出“意愿”，然后由系统找出最匹配的应用进程来完成相关工作。这样的设计极大地增强了系统的灵活性。举个例子，当用户点击了“Browser”按键后，他的“用意”（intent）是“浏览网页”，而至于是用哪个具体应用程序来响应这个“意愿”，则需要根据系统的具体情况来决定——假如同时有几个目标“候选者”（比如用户同时安装了多款浏览器），那么用户有权利来做最终的选择。关于Intent以及它的最佳匹配过程，在本书应用篇中有详细讲解。

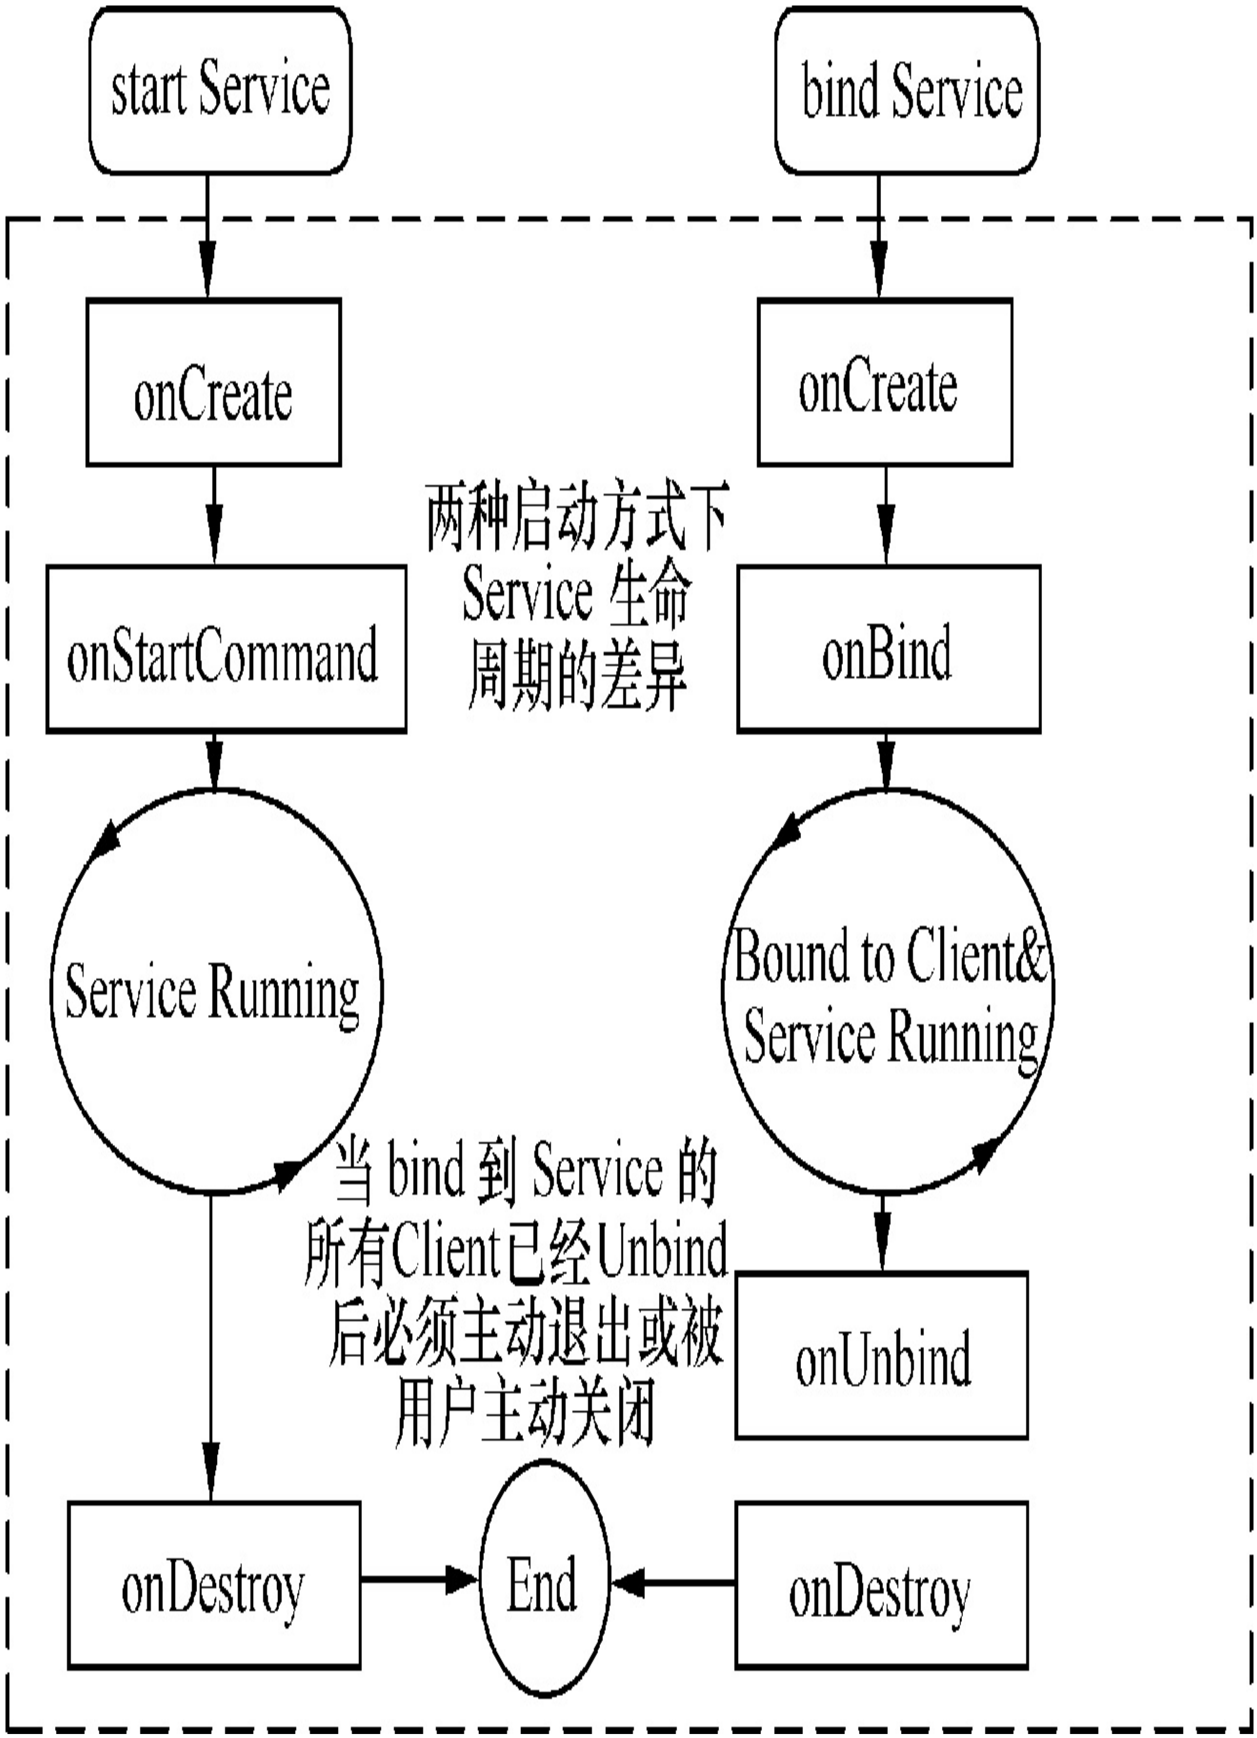
start Service
bind Service
onCreate
onCreate
两种启动方式下
Service 生命
周期的差异
onStartCommand
onBind
Service Running
Bound to Client&
Service Running
当 bind 到 Service 的
所有Client已经Unbind
后必须主动退出或被
用户主动关闭
onUnbind
onDestroy
End
onDestroy

▲图6-23　两种Service的生命周期

一方面，Android系统在底层Binder机制的基础上做了进一步的封装来满足应用程序的研发需求，从而使开发者不需要关心太多Binder的内部细节就可以实现各种跨进程的交互功能；而另一方面，也是开发人员对Binder原理感到陌生的一大主因——Android做得如此完美，以至于我们并没有感觉到进程间通信的“痕迹”。

下面将会选取bindService为例，向大家充分揭示隐藏在这些接口背后的Binder内部原理。

从上面的分析可知，应用程序“进程1”只需要调用Android已经提供的一系列接口方法就可以与“进程2”实现跨进程交互。那么，在这一过程中“进程2”的具体工作是什么呢？我们会很自然地想到，在TCP/IP通信中，当客户端发起连接请求时，服务器端必定是处于监听状态。这种C/S模型的交互方式在前几节分析Binder Client和Binder Server时已经被证实，如Service Manager就是在一个不断读取消息的循环中处理客户端的请求的。

值得一提的是，从Android应用程序的角度来看，Service组件并不等同于Binder Server。换句话说，它并不是一定要处于运行状态才能接收请求。Service组件的生命周期起始于startService或者bindService。而不管是哪一种启动方式，都是在客户端发出连接请求后才执行的，可见Service组件本身不存在“持续监听”的状态。

前一个小节给出了Binder的主体框架图，这里再从应用程序的角度对它进行完善，如图6-24所示。

由图可知，整个框架被一分为二，分别代表了Binder机制中对应用程序可见和隐藏的两部分。

- 可见部分

Android系统提供给应用程序的接口，组成了可见部分，包括bindService、startActivity等。

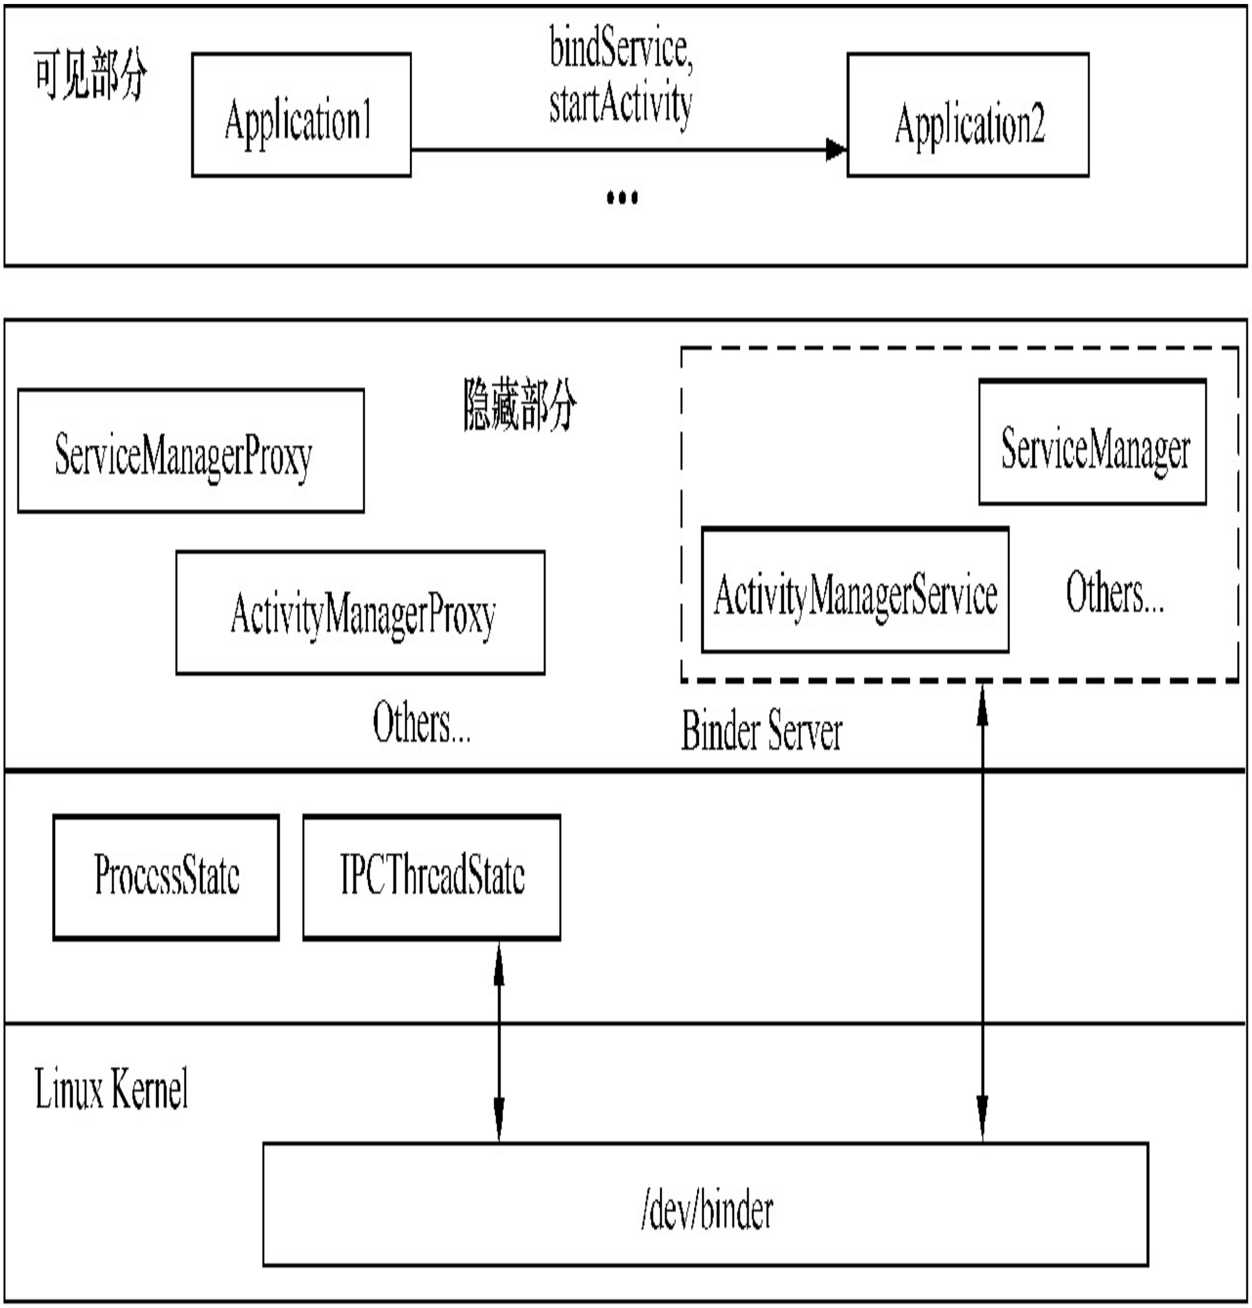

▲图6-24　从应用开发角度看Binder主体框架

- 隐藏部分

应用程序只需要通过上述可见接口便可以方便地完成IPC通信，但可以肯定的是隐藏在其后庞大的Binder通信原理还是没有变。

为了让大家可以更清楚地看到整个“隐藏部分”的内部实现，接下

来选取一个范例进行剖析。如图6-25所示，Application1中的某个Activity通过bindService(intent)来试图启动符合intent描述的Service服务——最终Application2中的Service将被运行。

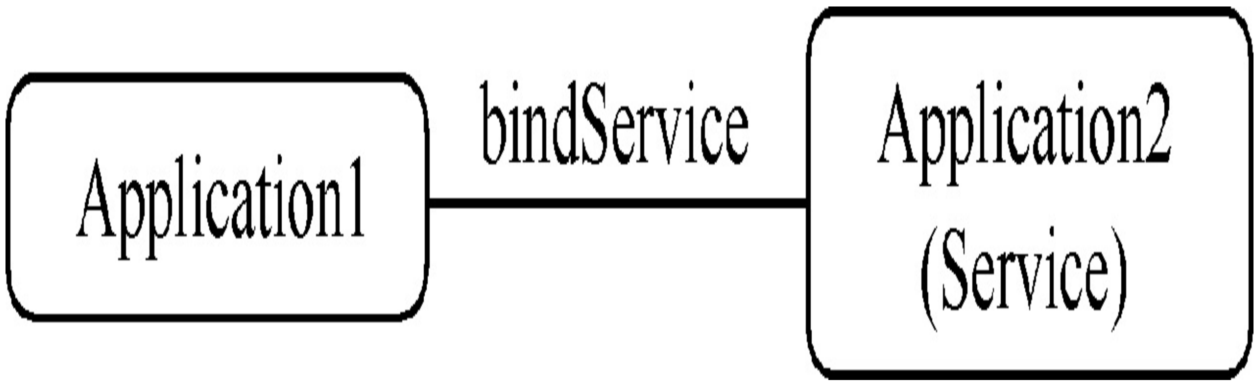

▲图6-25 bindService简图

应用程序如何能依托bindService来启动系统中其他进程提供的Service呢？别急，读者可以先来“庖丁解牛”——必定需要以下几个步骤才能完成这一操作目标。

- Step1. 应用程序填写Intent，调用bindService发出请求。
- Step2. 收到请求的bindService（此时还在应用程序的运行空间中）将与Activity ManagerService(AMS)取得联系。根据前面几个小节的分析，为了获得AMS的Binder句柄值，我们还要事先调用ServiceManager.getService，这里就已经涉及进程间通信了。在得到AMS的句柄值后，程序才能真正地向它发起请求（关于ActivityManagerService服务的详细讲解，可以参见本书后续章节）。
- Step3. AMS基于特定的“最优匹配策略”，从其内部存储的系统所有服务组件的资料中找到与Intent最匹配的一个，然后向它发送Service绑定请求（这一步也是进程间通信）——注意，如果目标进程还不存在的话，AMS还要负责把它启动起来。这部分知识在前面章节“应用程序的典型启动流程”中已分析过。
- Step4. “被绑定”的服务进程需要响应绑定，执行具体操作，并在成功完成后通知AMS；然后由后者再回调发起请求的应用程序（回调接口是ServiceConnection）。

由此可见，一个看似简单的bindService原来内部“大有乾坤”。但是为什么Application1在Activity中只需要调用bindService即可，而丝毫不见上述的烦琐过程呢？

我们知道，基于Activity应用程序的继承关系如图6-26所示。

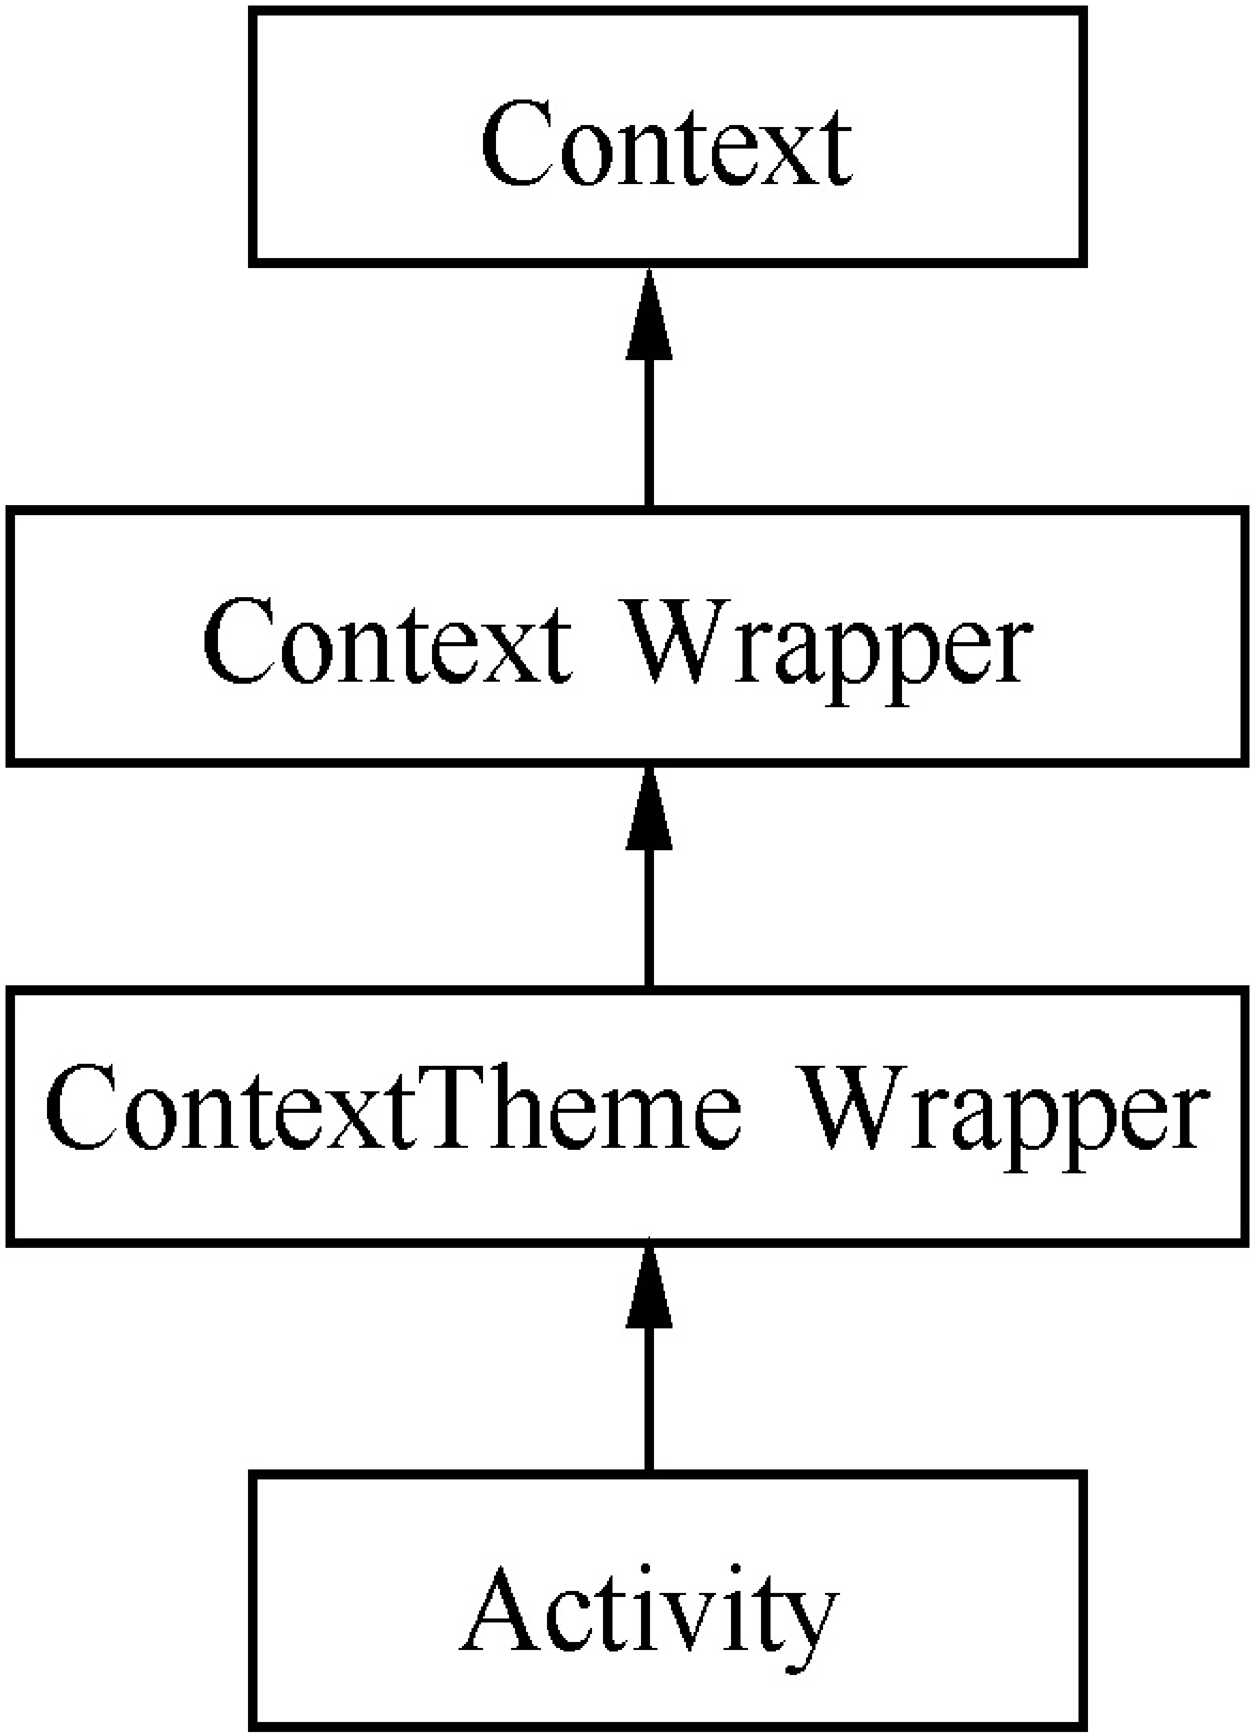
Context
Context Wrapper
ContextTheme Wrapper
Activity

▲图6-26　Activity的继承关系简图

由此可知，Activity继承关系的“根”是Context。从字面意思来理解，Context是“上下文环境”。运用到应用程序的场景中，就是指和一个Application环境相关的全局性信息。比如startActivity、startService、sendBroadcast、getResources等，都是每一个应用程序与生俱来的能力——好比每一个人生来就会呼吸、一个鼻子两个眼睛一样，是它的固有属性和功能。关于Context此处不再做过多渲染，有兴趣的读者看下代码就很清楚了，这里把它理解为应用程序的“全局而天生的能力”就行了。

所以bindService自然也是包含在Context里面的。具体而言，Context只是提供了抽象的接口，功能则是在ContextWrapper中实现的：

```
/*frameworks/base/core/java/android/content/ContextWrapper.java*/
    public boolean bindService(Intent service, ServiceConnection
        return mBase.bindService(service, conn, flags); //mBase是
    }
```

这个类取名为ContextWrapper是有一定道理的，因为它并不是Context环境实现的主体，更多的只是为mBase做了个转向功能。

上述变量mBase也是一个Context对象，最新版本中是由ContextImpl来实现的（bindService直接调用bindServiceAsUser）：

```
     /*frameworks/base/core/java/android/app/ContextImpl.java*/
    public boolean bindServiceAsUser(Intent service,ServiceConnec
                   UserHandle user) {…
        int res = ActivityManagerNative.getDefault().bindService(
                mMainThread.getApplicationThread(), getActivityTok
                service, service.resolveTypeIfNeeded(getContentRes
                sd, flags, userId); /*ActivityManager出现了，证明了我
        …
    }
```

那么，应用程序又是如何找到AMS并与之建立联系的呢？

和ServiceManager一样，AMS也同样提供了ActivityManagerNative和ActivityManagerProxy，具体如下：

```
 /*frameworks/base/core/java/android/app/ActivityManagerNativ
static public IActivityManager getDefault() {
    return gDefault.get(); /*得到默认的IActivityManager对象*/
}
```

这个gDefault.get()得到的是什么？

```
 /*frameworks/base/core/java/android/app/ActivityManagerNativ
 private static final Singleton<IActivityManager> gDefault =n
 Manager>() {
/*Singleton，即“单实例”是一种常见的设计模式，它保证某个对象只会被创建一
  当调用gDefault.get()时，会先进行内部判断:如果该对象已经存在，就直接i
  需要通过内部create()新建一个对象实例*/
 protected IActivityManager create() {
    IBinder b = ServiceManager.getService("activity");/*通过Se
                        取得ActivityManagerService的IBinde
    …
    IActivityManager am = asInterface(b); /*创建一个可用的Activi
    …
    return am;
  }
};
```

看出什么了吗？ActivityManagerNative的作用之一，就是帮助调用者方便快速地取得一个ActivityManagerProxy。这和ServiceManagerProxy及ServiceManagerNative的作用基本一致，只不过在细节上有略微差异。

在gDefault这个单实例中，获取一个有效的IActivityManager对象需要两个步骤，即：

- 得到IBinder（BpBinder）；
- 将IBinder转化为Iinterface（在这个场景中，是IactivityManager）。

因为ServiceManager提供了一系列静态方法，使得第一个步骤显得很简洁。

顺便说一下，ActivityManagerNative的另一个作用是为ActivityManagerService的实现提供便利。如果仔细观察，就会发现ActivityManagerNative里有如下方法：

```
public boolean onTransact(int code, Parcel data, Parcel reply, in
```

```
        switch (code) {
        case START_ACTIVITY_TRANSACTION:
        {
            …
            int result = startActivity(app, intent, resolvedType,
                    grantedUriPermissions, grantedMode, resultTo,
                    requestCode, onlyIfNeeded, debug, profileFile
                    profileFd, autoStopPro filer);
             …
        }
```

这样在AMS里只要继承自ActivityManagerNative，就已经将用户的业务请求码与自己的内部实现函数连接了起来，是不是很方便？源代码如下：

```
/*frameworks/base/services/java/com/android/server/am/ActivityMan
public final class ActivityManagerService extends ActivityManager
                                                              Activit
        implements Watchdog.Monitor, BatteryStatsImpl.BatteryCall
        …
```

因而可以这么说，ActivityManagerNative（其他服务的Native也是一样的）既是面向调用者的，也是面向服务实现本身的，只不过这个Native的名称取得容易产生歧义。

经过上面代码的分析，Application1和Application2的进程间通信还应该再加上ServiceManager和ActivityManagerService的支持，如图6-27所示。

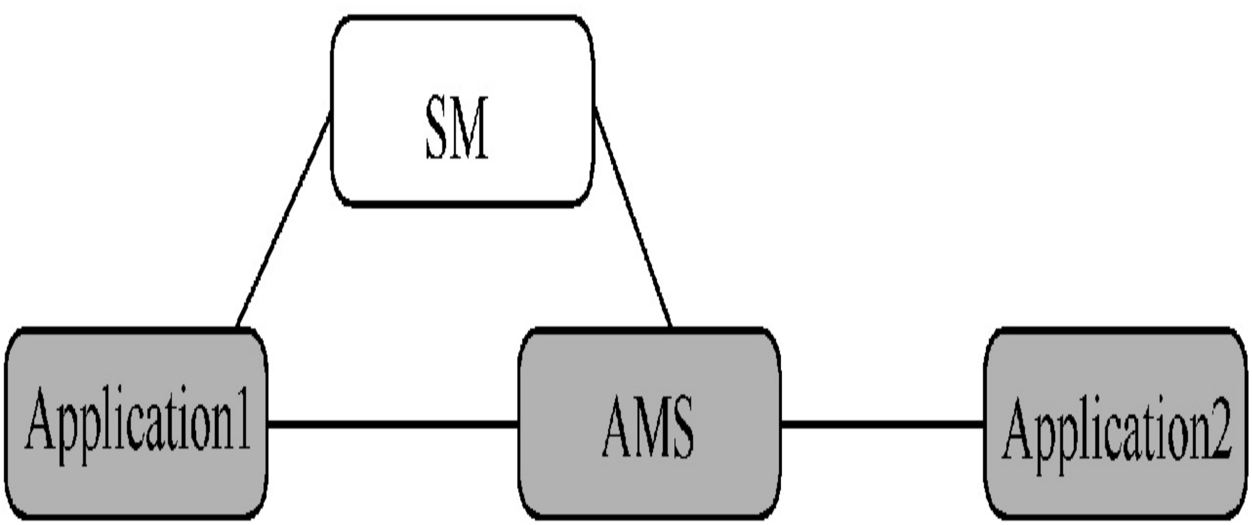

▲图6-27　Service Manager对进程间通信的支持

记住，不管形式怎么变，整个IPC通信都是基于Binder驱动来开展的。因而建议读者在思考问题时最好以Binder驱动为中心，以看得更“透彻”。

当应用程序需要通过ServiceManager来查询某个Binder Server时，调用的是getService方法。相关知识在前面小节已经详细分析过，这里再大概复习几个关键点。直接面向应用程序的是Service Manager.java，它提供了多个static接口供调用者获取ServiceManager提供的服务，如Service Manager.getService。这些静态函数内部通过getIServiceManager来得到ServiceManagerProxy对象——后者作为SM的本地代理，将利用IBinder来“穿越”JNI层调用到对应的BpBinder，进而使用ProcessState和IPCThreadState的相关接口，最终经由Binder驱动完成与ServiceManager的通信。

先总结一下到目前为止的函数调用过程，如图6-28所示。

从图6-28中可以看到，“万里长征”还只是走了前两步（Step1和Step2），即Application1已经可以访问到AMS，并向后者请求bindService了。接下来AMS要针对bindService中指定的Intent进行一系列匹配工作，然后确定需要启动的Service及它所属的进程。这部分内容与AMS的工作原理有很大关系，我们将在后续章节进行统一解答。

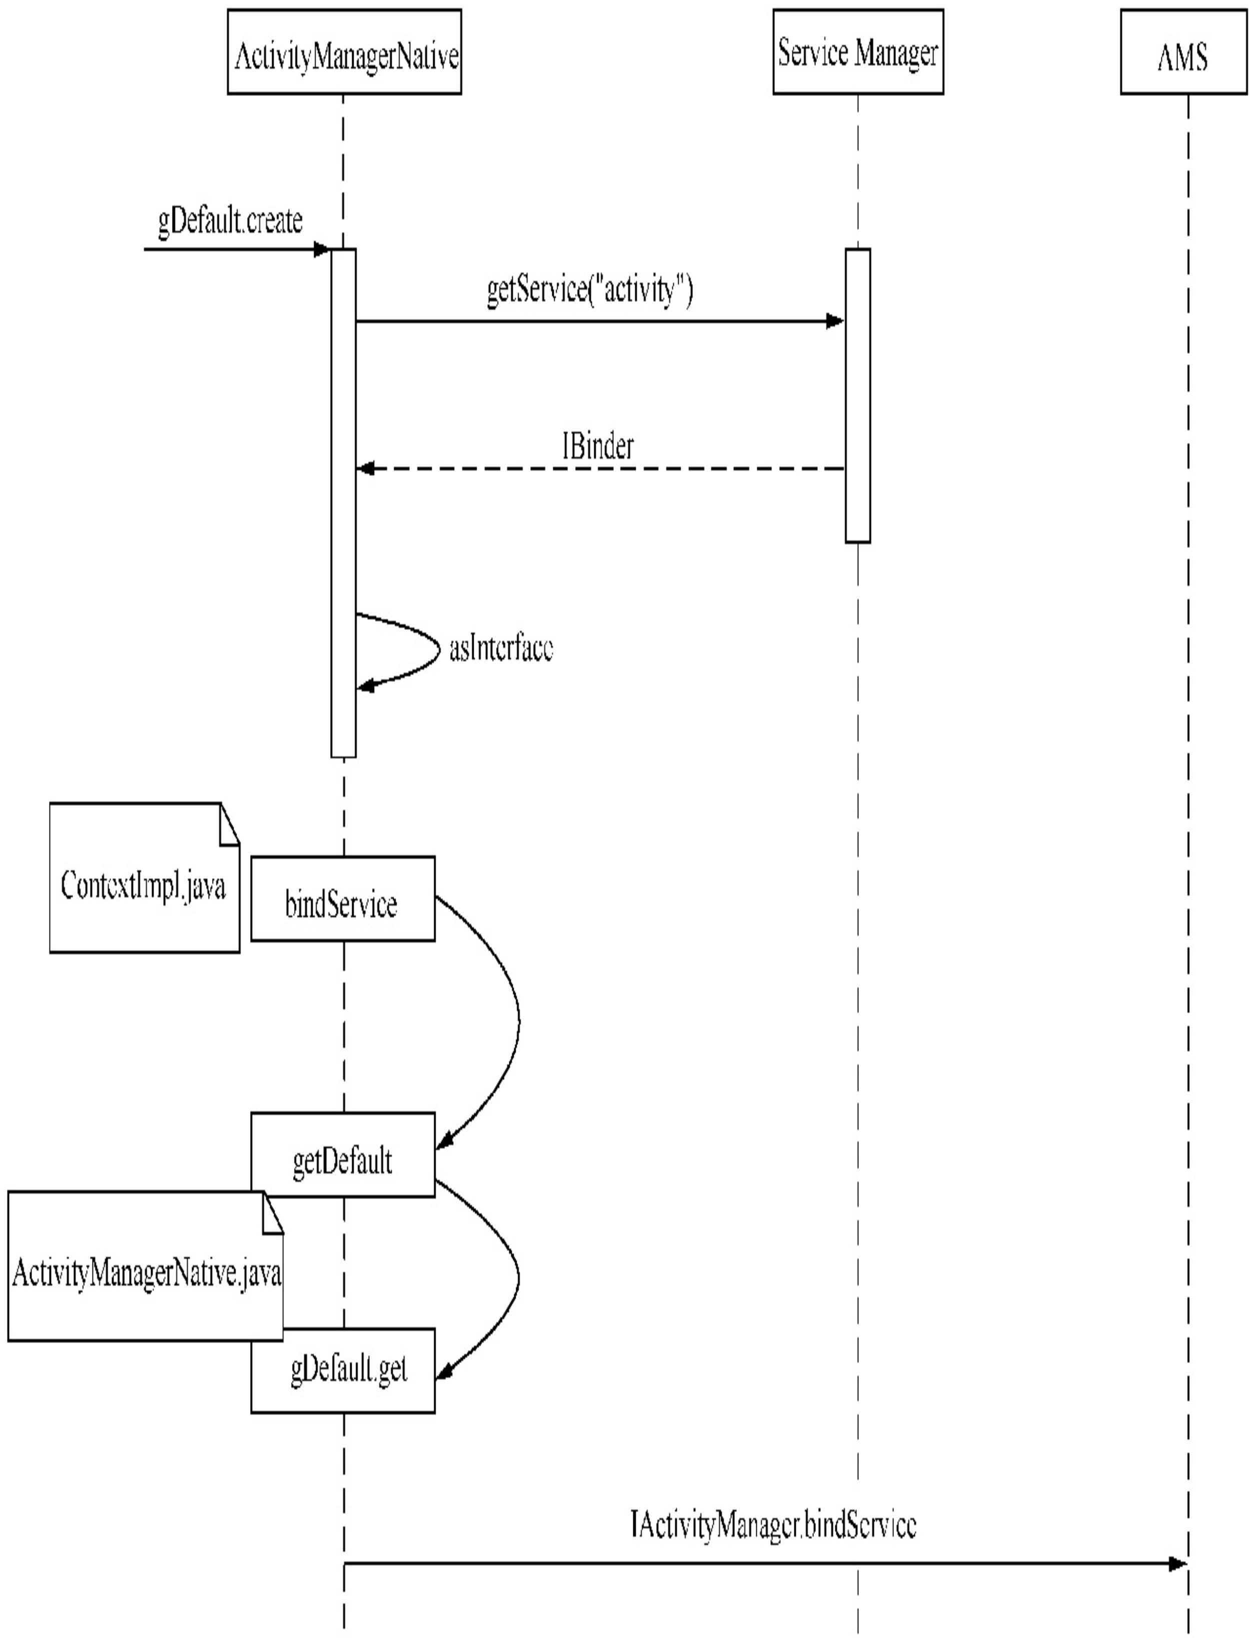

ActivityManagerNative
Service Manager
AMS
gDefault.create
getService("activity")
IBinder
asInterface
ContextImpl.java
bindService
getDefault
ActivityManagerNative.java
gDefault.get
IActivityManager.bindService

▲图6-28　bindService 调用流程

本小节以一个简单的接口函数bindService为切入点，向大家展示了隐藏在应用程序背后的Binder机制。从中可以看出，Google为了简化应用开发人员的工作可谓用心良苦——不过由此带来的一个负面影响就是，整个Binder的“上层建筑”显得非常烦琐。希望读者在学习这部分知识时，能够始终掌握“Binder驱动”这一核心，并在此基础上层层递进来逐步理解Android所做的封装，相信就能跳出冗长的代码“陷阱”了。

6.6 Android接口描述语言——AIDL

AIDL是Android Interface Description Language的简写。从名称上看它是一种语言，而且是专门用于描述接口的语言。准确地说，它是用于定义客户端/服务端通信接口的一种描述语言。这么说大家可能觉得比较抽象，接下来我们尝试从另一个角度来理解。

如前面小节反复强调的，Service Manager本身也是一个Binder Server，为Binder Client提供了一系列服务接口。仅从Service Manager的实现来看，构建一个Binder Server所需的工作如下。

1．启动的时机

比如SM是开机的时候通过init.rc文件启动的，这就保证了它是系统中第一个注册成“服务大管家”的Service。

2．提供一致的服务接口

显然，一个Binder Server应该向公众暴露它所能提供的服务；而且客户端使用的服务接口和服务端实现的服务接口必须是完全一致的。

SM中的服务接口是IServiceManager。客户端本地进程中的ServiceManagerProxy及ServiceManagerNative都继承自这个接口。而它的服务端是直接用C语言实现的（Service_manager.c），所以不存在继承的说法。不过通过分析其内部binder_parse函数可知，它还是保持了与客户端接口的一致。

3．与Binder驱动的交互方式

一个Binder Server需要与Binder Driver做哪些交互呢？除去一系列必要的初始化以外（open，mmap等），就是要通过不断地ioctl来循环读写数据。比如SM就是通过binder_loop函数中的一个for死循环来完成这一工作的。

4．外界如何能访问到这个Server的服务

一个Server最终的价值在于向Client提供服务，所以自然会有一个

问题，即Client如何去访问一个Server？回想一下前几个小节讲过的关于Binder Server的知识，至少有两种方法是可行的。

方法1：Server在ServiceManager中注册。

这种方法普遍存在于Android系统服务中，如ActivityManagerService、WindowManagerService等都在ServiceManager中做了注册。调用者只要通过ServiceManager.getService(SERVICE_NAME)就可以获取到Binder Server的本地代理，然后与之通信。

方法2：通过其他Server作为中介。

这是一种“匿名”的方法。换句话说，这种类型的Binder Server不需要在ServiceManager中注册。那么，客户端如何访问它呢？

没错，就是通过一个“第三方”的“实名”Server——因为是实名的，调用者可以通过ServiceManager来首先访问到它，然后由它提供的接口获取“匿名”者的Binder句柄。举个互联网中的例子，我们访问某服务器A通常要先由DNS做域名解析，获取到IP地址后才能访问网站。但这不是唯一可行的方法。假设服务器B已经在DNS中注册，并且通过服务器B可以得到A的IP地址，那么理论上客户端就可以这么做：

通过DNS获得服务器B的IP地址→访问服务器B→向服务器B查询A的IP地址→访问服务器A

在这种情况下，实际上服务器B就扮演了DNS的角色。

我们把这种实现方式称为“匿名”Binder Server。它在Android系统中也比较常见，如后面章节中将会讲解的WindowSession就属于这一类。

以上几点就是一个Binder Server构建所需要做的核心内容。我们在Service Manager的学习中会发现，它基本上是靠开发人员一行行手工编写出来的。那么，有没有其他更简捷的方式来实现一个Binder Server呢？

答案就是AIDL。

当然，不管是手工还是自动，所要做的核心内容并没有太大变化；只是自动化可以帮助开发人员更快速地组建出Binder Server。本小节内容将通过一个范例来分析采用AIDL究竟可以为Binder Server带来哪些便利以及它的内部实现原理。

这个范例是本书显示系统章节中将会重点讨论的WindowManagerService。

（1）先来看看启动时机的问题。和其他系统服务一样，WMS是在SystemServer中启动的，具体过程可以参见WMS章节，这里暂且跳过。

（2）再来看看AIDL是如何保证接口的一致性的。使用AIDL首先要书写一个*.aidl文件来描述这个Server。比如：

```
/*IWindowManager.aidl*/
interface IWindowManager
{…
IWindowSession openSession(in IInputMethodClient client,in IInput
…
}
```

为了让大家看得更清楚些，上述代码段只保留了openSession一个接口方法，其余部分可以参考WindowManagerService章节的描述。

AIDL的语法细节这里就不详细讲解了。这个IWindowManager.aidl文件经过工具转化后，成为以下内容：

```
/*IWindowManager.java*/
public interface IWindowManager extends android.os.IInterface
{
public static abstract class Stub extends android.os.Binder //Stu
implements android.view.IWindowManager
{
public static android.view.IWindowManager asInterface(android.os.
{
…
}
@Override public android.os.IBinder asBinder()
{
return this;
}
@Override public boolean onTransact(int code, android.os.Parcel d
android.os.Parcel reply, int flags) throws android.os.RemoteExcep
```

```
{
switch (code)
{
case TRANSACTION_openSession:
{
…
}…
}
return super.onTransact(code, data, reply, flags);
}
private static class Proxy implements android.view.IwindowManager
//Proxy就是“代理”，我们已经多次讲解
{
private android.os.IBinder mRemote;
…
@Override public android.os.IBinder asBinder()
{
return mRemote;
}
@Override public android.view.IWindowSession
 openSession(com.android.internal.view.IInputMethodClient client,
 com.android.internal.view.IInputContext inputContext) throws and
{
…
}
} //Proxy结束
}//Stub结束
…
static final int TRANSACTION_openSession =(android.os.IBinder.FIR
/*自动分配业务码，大家可以和ServiceManager中的手工分配做下对比*/
}//IWindowManager结束
```

这个文件很长，而且因为通过AIDL工具自动生成的内容没有格式，看起来比较吃力。我们尽可能省略掉无关部分，并将重要的3个类高亮显示，即IwindowManager、IWindowManager.Stub和IWindowManager.Stub.Proxy。后两个类是嵌套类，并继承自IWindowManager。

- IWindowManager

一般以大写字母I开头的表示一个Interface。在AIDL中，所有的服务接口都继承于Iinterface，然后在此基础上声明与此Server服务相关的方法。比如IWindowManager中除了两个嵌套类外，其末尾还包含了它提供的服务openSession、getRealDisplaySize、hasSystemNavBar等接

口的原型。

- IWindowManager.Stub

还记得ServiceManagerNative吗？Stub的作用和它类似。它包含了一个嵌套类（Stub.Proxy），以及各种常用的接口方法（如asInterface，asBinder等），其中最重要的一个就是onTransact。我们知道ServiceManagerNative是同时面向服务器和客户端的，Stub也同样如此。在实际使用中，一个Binder Server的实现类通常继承自Stub。而Stub又继承自Binder并实现了该Server的IXX接口，如IWindowManager的实现类WindowManagerService：

```
public class WindowManagerService extends IWindowManager.Stub
```

至于为什么要继承自Binder类，后面会有详细分析。

- IWindowManager.Stub.Proxy

Proxy即代理，功能和ServiceManager Proxy类似。因而这个类是面向Binder Client的，它可以让调用者轻松地构造出Binder Server的本地代理对象。

具体如图6-29所示。

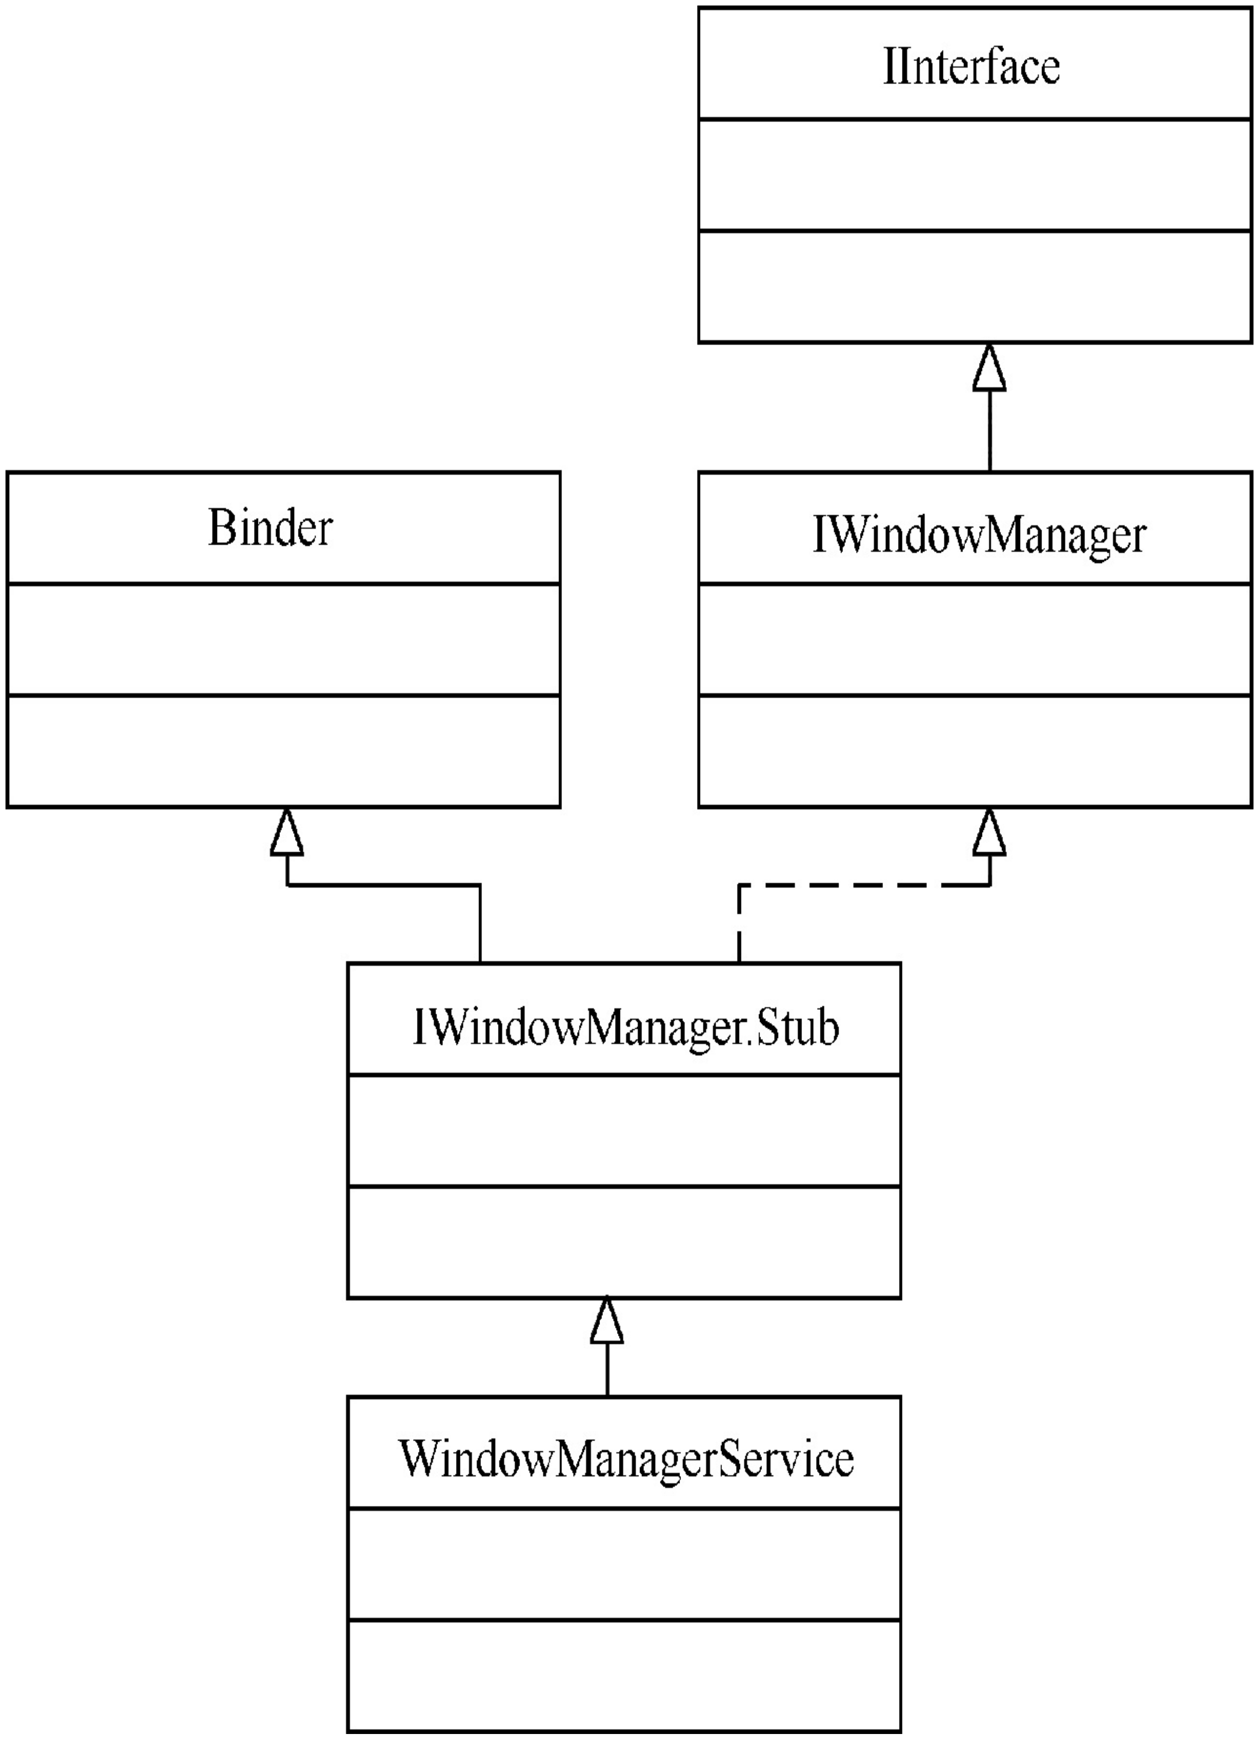
IInterface
Binder
IWindowManager
IWindowManager.Stub
WindowManagerService

▲图6-29　基于AIDL的Binder Server

这样通过AIDL就为WMS这个Binder Server生成了统一的服务接口。

（3）接下来看第三个问题，即基于AIDL的Binder Server如何与Binder驱动进行交互。在Service Manager的实现中，它通过死循环不停地执行ioctl来获取用户的请求。而一个Client在获取Service Manager的服务时，则是通过ProcessState和IPCThreadState来处理各种细节。那么，WindowManagerService这个使用AIDL的Server又是如何实现的呢？

如果读者只是单纯地阅读WMS的源码，可能很难发现谜底所在，所以需要换一种思路。我们在系统的启动过程章节讲解过系统服务（比如WindowManagerService、PowerManagerService、LocationManagerService等）相关的知识——这些服务统一都在SystemServer.java中启动。而在这之前，即System_init.cpp中其实还隐藏着这么一段代码：

```
/*frameworks/base/cmds/system_server/library/System_init.cpp*/
extern "C" status_t system_init()
{
    …
    ALOGI("System server: entering thread pool.\n");
    ProcessState::self()->startThreadPool();
    IPCThreadState::self()->joinThreadPool();
}
```

通过这两句代码，整个系统服务进程就进入类似于Service Manager中的binder_loop循环了。因为后续在SystemServer中启动的所有系统服务都运行于同一个进程中，所以它们就没有必要再单独与Binder驱动进行交互。下面具体看看这两句代码都做了些什么：

```
/*frameworks/native/libs/binder/ProcessState.cpp*/
void ProcessState::startThreadPool()
{
    AutoMutex _l(mLock);
    if (!mThreadPoolStarted) {
        mThreadPoolStarted = true;//表明已经启动了线程池了，避免重复操作
        spawnPooledThread(true);//产生一个线程池，注意传参为true
    }
}
```

其中mThreadPoolStarted用来标识ThreadPool是否已经开启。上述代码段的重点还在spawnPooledThread中：

```
void ProcessState::spawnPooledThread(bool isMain)//这里的参数为true
{
    if (mThreadPoolStarted) {
        String8 name = makeBinderThreadName();/*为线程池取名*/
        ALOGV("Spawning new pooled thread, name=%s\n", name.strin
        sp<Thread> t = new PoolThread(isMain);/*生成线程池对象*/
        t->run(name.string());//运行
    }
}
```

这个函数的逻辑很简单，首先为PoolThread取一个名字，然后新建PoolThread对象，最后执行run函数（从中也可以看出，线程池必定是一个Thread子类）：

```
/*frameworks/native/libs/utils/Threads.cpp*/
status_t Thread::run(const char* name, int32_t priority, size_t s
{…
    if (mCanCallJava) {
        res = createThreadEtc(_threadLoop,this, name, priority, s
    } else {
        res = androidCreateRawThreadEtc(_threadLoop,this, name, p
    }
    …
}

int Thread::_threadLoop(void* user)
{
    …
    result = self->threadLoop()
}
```

本地层的Thread和Java层的实现还是有所区别的，如上面代码段所示。它的run函数最终调用的是PoolThread的threadLoop：

```
class PoolThread : public Thread
{…
protected:
    virtual bool threadLoop()
    {
        IPCThreadState::self()->joinThreadPool(mIsMain);//注意这个i
        return false;
    }
```

```
    const bool mIsMain;
};
```

可以看到，在threadLoop中也调用了一次joinThreadPool，而且mIsMain为true。

这样就进入joinThreadPool了。它的功能类似于Service Manager中binder.c的binder_loop：

```
void IPCThreadState::joinThreadPool(bool isMain)
{
    mOut.writeInt32(isMain ? BC_ENTER_LOOPER : BC_REGISTER_LOOPER
    …
    status_t result;
    do {//这就是Binder Server处理消息的主循环了
        int32_t cmd;
        …
        result = talkWithDriver();//这个函数前面小节中已经分析过了
        if (result >= NO_ERROR) {
            size_t IN = mIn.dataAvail();//有没有可读数据？
            if (IN < sizeof(int32_t)) continue;
            cmd = mIn.readInt32();//读取一个cmd
            …
            result = executeCommand(cmd);//执行cmd
        }
       …
        if(result == TIMED_OUT && !isMain) {//超时，而且不是主要的Bi
            break;
        }
    } while (result != -ECONNREFUSED && result != -EBADF);
    …
    mOut.writeInt32(BC_EXIT_LOOPER);//告知Binder驱动退出循环
    talkWithDriver(false);
}
```

上面的while主循环不断地talkWithDriver然后executeCommand，这和binder_loop的主体框架基本是一致的——也就解决了Binder Server如何与Binder驱动通信的问题。

（4）最后还有一个疑问是我们必须要搞清楚的，即当一个进程中有多个Binder Server存在时，基于AIDL的实现是如何正确区分它们的（因为ProcessState是单实例）？

在ServiceManager中，这并不是问题。因为整个SM进程就一个

Server，只要Binder驱动有数据要处理，当然非它莫属（直接调用binder_parse进行处理即可）。而当一个进程中存在多个Binder Server（比如SystemServer就是这种情况，其所在进程中有WindowManagerService，ActivityManagerService等一系列系统服务）时，IPCThreadState是如何把Binder驱动的消息准确投递给对应的Server的？

有的读者可能会想，让IPCThreadState记录下进程中的所有Binder Server即可。理论上的确可行，不过显然会使程序的逻辑变得复杂——因为我们想要做的是向上层隐藏一切与Binder底层相关的操作，做到“无缝”连接。

来看看executeCommand是怎么做到的：

```
status_t IPCThreadState::executeCommand(int32_t cmd)
{
    BBinder* obj;
    RefBase::weakref_type* refs;
    status_t result = NO_ERROR;
    switch (cmd) {…
    case BR_TRANSACTION:
    {
        binder_transaction_data tr;
        result = mIn.read(&tr, sizeof(tr));/*读取业务请求*/
        …
        Parcel buffer;
        buffer.ipcSetDataReference(einterpret_cast<const uint8_t*
        tr.data_size,
        reinterpret_cast<const size_t*>(tr.data.ptr.offsets),
                    tr.offsets_size/sizeof(size_t),freeBuffer, th
        …
        Parcel reply;
        …
        if (tr.target.ptr) {/*如果target中指定了目标对象*/
            sp<BBinder> b((BBinder*)tr.cookie);/*强制类型转换为BBin
            const status_t error = b->transact(tr.code, buffer, &
            if (error < NO_ERROR) reply.setError(error);
            } else {
               const status_t error = the_context_object->transac
               tr.flags);
               if (error < NO_ERROR) reply.setError(error);
            }
               …
        }
```

```
        break;
          …
    }
    …
    return result;
}
```

在对BR_TRANSACTION的处理中，首先整理出请求数据，然后分成两种情况。

- tr.target.ptr不为null

将tr.cookie强制转换成一个BBinder，最后调用BBinder->transact来处理请求。

- tr.target.ptr为null

此时使用默认的the_context_object来处理请求。

通常情况下程序走的是上面的分支，看来这个BBinder就是Server和IPCThreadState沟通的桥梁。那么，BBinder又是什么时候生成的呢？而且为什么Client发起的请求中会知道这个信息？

细心的读者在刚才IWindowManager.java中应该已经发现了，Stub是继承于Binder的。即：

```
public static abstract class Stub extends android.os.<strong>Bind
```

因为Stub类在构造时只是简单地调用attachInterface来设置了owner和descriptor，我们直接来看看Binder的构造：

```
/*frameworks/base/core/java/android/os/Binder.java*/
    public Binder() {
          init();
          …
    }
```

这个init是一个native函数，具体实现如下：

```
/*frameworks/base/core/jni/android_util_Binder.cpp*/
static void android_os_Binder_init(JNIEnv* env, jobject obj)
{
```

```
    JavaBBinderHolder* jbh = new JavaBBinderHolder();
    …
    jbh->incStrong((void*)android_os_Binder_init);
    env->SetIntField(obj, gBinderOffsets.mObject, (int)jbh);
}
```

上述代码段首先生成一个JavaBBinderHolder对象，从名称上看它是BBinder的载体，内部持有一个JavaBBinder的弱引用，而后者又继承自BBinder。另外，它提供了一个get方法用于获取内部的这个JavaBBinder的强引用（通过promote转换），后面还会碰到这个方法的使用场景。值得注意的是，这里新建的JavaBBinderHolder对象并没有立刻生成JavaBBinder，而是要等到有人调用时它才会真正创建出来。

接着init函数增加了强引用计数，并通过JNI把这个JavaBBinderHolder的指针值保存到Binder的mObject内部变量中，以便后续使用。这样我们就很清楚了，当一个基于AIDL的Server创建时，它就已经“有预谋”地要生成BBinder了。这个“预谋”等到有人真正使用它来进行跨进程传递时，才会实施。比如在创建WMS的同时，会把它注册到Service Manager中：

```
/*frameworks/base/services/java/com/android/server/SystemSer
Slog.i(TAG, "Window Manager");
wm = WindowManagerService.main(context, power, display, inpu
           uiHandler, wmHandler,factoryTest != SystemServer.
           !firstBoot, onlyCore);
ServiceManager.addService(Context.WINDOW_SERVICE, wm);
```

关于ServiceManager前面小节已经详细分析过，这里看下addService的核心内容（注意，ServiceManager并不是和WindowManagerService一样运行在系统服务进程中，而是通过init.rc启动）：

```
public void addService(String name, IBinder service, boolean allo
        Parcel data = Parcel.obtain();
        …
        data.writeStrongBinder(service);//写入一个StrongBinder
        …
    }
```

上面的语句中使用了writeStrongBinder将service（在这个场景中，也就是WindowManager Service自身）写入Parcel中：

```
/*frameworks/base/core/jni/android_os_Parcel.cpp*/
static void android_os_Parcel_writeStrongBinder(JNIEnv* env, jcla
{
    Parcel* parcel = reinterpret_cast<Parcel*>(nativePtr);
    if (parcel != NULL) {
        const status_t err = parcel->writeStrongBinder(ibinderFor
        …
    }
}
```

我们直接从JNI的实现看起。当生成一个Parcel(java)对象时，会在构造函数中通过nativeCreate同时生成一个native层的Parcel对象，并将它的内存地址保存到Parcel(java)中，即上面代码中的nativePtr。另外函数入参里的object是一个IBinder(java)对象，需要通过ibinderForJavaObject进行转化。如下所示：

```
/*frameworks/base/core/jni/android_util_Binder.cpp*/
sp<IBinder> ibinderForJavaObject(JNIEnv* env, jobject obj)
{
    if (obj == NULL) return NULL;
    if (env->IsInstanceOf(obj, gBinderOffsets.mClass)) {
        JavaBBinderHolder* jbh = (JavaBBinderHolder*)env->GetIntF
        mObject);
        return jbh != NULL ? jbh->get(env, obj) : NULL;
    }
    …
    return NULL;
}
```

这个函数中出现了我们前面看到的JavaBBinderHolder，它是通过Binder.mObject变量保存的。因而这里再利用gBinderOffsets.mObject把它取出来，紧接着调用JavaBBinderHolder.get方法：

```
    sp<JavaBBinder> get(JNIEnv* env, jobject obj)
    {
        AutoMutex _l(mLock);
        sp<JavaBBinder> b = mBinder.promote();
        if (b == NULL) {/*第一次*/
            b = new JavaBBinder(env, obj);
            mBinder = b;
        }
        return b;
    }
```

因为是第一次调用，所以需要new一个JavaBBinder对象，它实际上是一个BBinder。这样ibinderForJavaObject得到的是一个JavaBBinder的强指针，接下来看下如何把它写入Parcel中：

```
/*frameworks/native/libs/binder/Parcel.cpp */
status_t Parcel::writeStrongBinder(const sp<IBinder>& val)
{
    return flatten_binder(ProcessState::self(), val, this);
}
```

上面代码段直接调用了flatten_binder：

```
/*frameworks/native/libs/binder/Parcel.cpp*/
status_t flatten_binder(const sp<ProcessState>& proc,const sp<IBi
                              Parcel* out)
{
    flat_binder_object obj;

    obj.flags = 0x7f | FLAT_BINDER_FLAG_ACCEPTS_FDS;
    if (binder != NULL) {
        IBinder *local = binder->localBinder();
        if (!local) {
            …
        } else {/*走的是这个分支*/
              obj.type = BINDER_TYPE_BINDER;
              obj.binder = local->getWeakRefs();
              obj.cookie = local;
          }
    } else {
        …
    }

    return finish_flatten_binder(binder, obj, out);/*把obj写入Parc
}
```

首先变量binder不为null，而且binder->localBinder()得到BBinder自身也不为空，所以obj的类型是BINDER_TYPE_BINDER；cookie记录的是BBinder这个对象。最后调用finish_flatten_binder把obj写入out中，即通过writeObject把obj写到Parcel空间的相应位置。经过这一系列操作后，我们就把一个Binder对象填充到Parcel中了。当后续向Binder驱动发起ioctl时，它会作为数据的一部分发过去。我们来看看这部分的处理：

```
/*(内核工程): drivers/staging/android/Binder.c*/
```

```
static void binder_transaction(struct binder_proc *proc,struct bi
                      struct binder_transaction_data *tr, int rep
{
     …
     off_end = (void *)offp + tr->offsets_size;/*offset区域(也就是在
     for (; offp < off_end; offp++) {/*object很有可能不只一个，所以逐
          struct flat_binder_object *fp;
          …
          fp = (struct flat_binder_object *)(t->buffer->data + *o
          switch (fp->type) {
          case BINDER_TYPE_BINDER:/*BINDER类型的情况下*/
          case BINDER_TYPE_WEAK_BINDER: {
               struct binder_ref *ref;
               struct binder_node *node = binder_get_node(proc, f
               if (node == NULL) {/*这是一个新节点*/
                    node = binder_new_node(proc, fp->binder, fp->
                    …
               }
               …
               ref = binder_get_ref_for_node(target_proc, node);
               …
               if (fp->type == BINDER_TYPE_BINDER)
                    fp->type = BINDER_TYPE_HANDLE;//做转换
               else
                    fp->type = BINDER_TYPE_WEAK_HANDLE;
               fp->handle = ref->desc;
               …
          } break;
          …
}
```

在Binder驱动的设计中，只要用户携带一个Binder对象“路过”它，就会被记录下来。在上面的代码中，binder_get_node会查找当前proc中的nodes树中是否已经存在这一Binder对象（以fp➞binder为关键字），否则就生成binder_new_node一个binder_node节点并把它加入nodes树中。因而属于当前Proc的所有Binder对象在驱动中都是有记录的：

```
struct binder_node {
     …
     union {
          struct rb_node rb_node;
          struct hlist_node dead_node;
     };
     struct binder_proc *proc; //此Binder对象所属的进程
     …
```

```
    void __user *ptr;  //fp->binder
    void __user *cookie;//额外信息，比如这个场景中对应的是BBinder对象的
    …
};
```

在这个场景中，WindowManagerService这个Binder对象就记录在Android系统服务进程中。那么，Client是如何找到它的呢?因为我们在target_proc中要添加一个指向此binder_node的引用：binder_get_ref_for_node。这个函数会查找proc->refs_by_node树中是不是已经存在这样的节点，否则就生成一个binder_ref节点并按顺序加入refs_by_node树中：

```
struct binder_ref {
    …
    struct rb_node rb_node_desc;
    struct rb_node rb_node_node;
    …
    struct binder_proc *proc; //binder_node所属的进程
    struct binder_node *node; //这个ref所指向的binder_node
    uint32_t desc; //ref编号，逐渐递增
    …
};
```

这个数据结构中有两个红黑树节点，即rb_node_desc和rb_node_node，前者将使binder_ref被加入proc-> refs_by_desc树（desc可能是description的缩写），而后者则加入refs_by_node。为什么同一个节点要加入两棵树中呢？一种合理的解释是这两种排序方法可以在不同的场合提高检索效率。另外，desc编号是随着新节点的加入而不断递增的，因而能保证它的唯一性。执行完这些操作后，fp->type类型就被改成BINDER_TYPE_HANDLE，而fp->handle则是ref->desc。当target被唤醒时，它的proc中已经有了指向binder_node的binder_ref节点了，而且fp中记录了此binder_ref的desc值。

清楚了BBinder的由来后，我们接着刚才的executeCommand函数往下看：

```
sp<BBinder> b((BBinder*)tr.cookie);
const status_t error = b->transact(tr.code, buffer, &reply, tr.fl
```

这里首先调用了BBinder的transact函数：

```
/*frameworks/native/libs/binder/Binder.cpp*/
```

```
status_t BBinder::transact(uint32_t code, const Parcel& data, Par
{
    data.setDataPosition(0);

    status_t err = NO_ERROR;
    switch (code) {
        case PING_TRANSACTION:
            reply->writeInt32(pingBinder());
            break;
        default:
            err = onTransact(code, data, reply, flags);
            break;
    }
    …
    return err;
}
```

除了PING_TRANSACTION的情况外，其他事项一律调用onTransact来处理。而JavaBBinder重载了这个方法：

```
/*JavaBBinder@android_util_Binder.cpp*/
virtual status_t onTransact(uint32_t code, const Parcel& data, Pa
                                  uint32_t flags = 0)
    {
        JNIEnv* env = javavm_to_jnienv(mVM);
        IPCThreadState* thread_state = IPCThreadState::self();
        const int strict_policy_before = thread_state->getStrictM
        thread_state->setLastTransactionBinderFlags(flags);
        jboolean res = env->CallBooleanMethod(mObject, gBinderOff
                                      code, (int32_t)&data, (int3
        …
    }
```

显然这个函数的重点就是调用Java层Binder对象（即ADIL中Stub类的父类）的某个接口来把用户请求传递过去。这个接口是Binder.execTransact，已经预先存储在gBinderOffsets.mExecTransact了：

```
/*Binder.java*/
private boolean execTransact(int code, int dataObj, int replyObj,
        Parcel data = Parcel.obtain(dataObj);
        Parcel reply = Parcel.obtain(replyObj);
        boolean res;
        try {
            res = onTransact(code, data, reply, flags);
```

```
        } catch (RemoteException e) {
          …
        return res;
    }
```

终于把Binder Client的请求传递到Binder(java)了，因为涉及JNI的中间处理过程，使得整个逻辑显得臃肿而复杂。事情还没结束，因为每个Binder Server肯定会有自己的业务码，所以它们都要重写onTransact接口，如WindowManagerService.java中：

```
    @Override
    public boolean onTransact(int code, Parcel data, Parcel reply
        try {
            return super.onTransact(code, data, reply, flags);
        } catch (RuntimeException e) {
            …
        }
    }
```

这个onTransact似乎什么也没做。

是的。由于AIDL自动生成的Stub类也重写了onTransact，而且已经为开发者做好了无缝跳转，所以我们在编写基于AIDL的Server时，只要实现相应的业务处理接口就行了。比如：

```
/*IWindowManager.java*/
@Override publicboolean onTransact(int code, android.os.Parcel da
{
switch(code)
{
case TRANSACTION_openSession:
{
…
android.view.IWindowSession _result = this.openSession(_arg0, _ar
reply.writeNoException();
reply.writeStrongBinder((((_result!=null))?(_result.asBinder()):(
returntrue;
}
```

上面代码中的this.openSession会调用openSession@WindowManagerService.java，而且还负责将结果写入Parcel并通过Binder驱动返回给调用者——对比SM中的手工实现是不是方便了很多？

这样我们就以WindowManagerService为例，完整地分析了基于AIDL的Binder Server的实现流程。

最后小结一下，仍然按照本节开头提出的几个疑问来展开。

- 启动时机问题

WMS是在System_Server中启动的。

- 如何提供一致的服务接口

通过分析aidl文件以及由它转化生成的java接口文件，我们知道一个AIDL接口包括了IwindowManager，IWindowManager.Stub和IWindowManager.Stub.Proxy三个重要类。后两者分别面向于WMS的服务端和Binder Client本地代理的实现，且都继承于IWindowManager，因而就保证了Client和Server是在完全一致的服务接口上进行通信的。

- 如何与Binder驱动交互的

通过解析，我们发现原来系统服务进程在一开始就调用了：

```
ProcessState::self()->startThreadPool();
IPCThreadState::self()->joinThreadPool();
```

它们将导致程序最终进入一个类似于binder_loop的主循环。因而，在这个进程中的Binder对象都可以不用单独与驱动进行交互。

- Client如何准确地访问到目标进程中的Binder Server

有两种方式可以让Binder Server可知，其一是通过在SM中注册，也就是WMS所属的情况。其二就是下一小节我们会谈到的匿名Server实现。对于实名的Server，当它利用addService来把自身注册到SM中时，会“路过”Binder驱动，而后者就会按计划把这一Binder对象链接到proc-> nodes，以及target_proc-> refs_by_desc和target_proc-> refs_by_node中。在这一场景中，proc是系统服务进程，而target_proc则是SM。也就是说，SM中拥有了一个描述WMS的binder_node的引用。这样当一个Binder Client通过getService向SM发起查询时，后者就可以准确地告知这个调用者它想访问的WMS节点所在

的位置。这就是前面我们在分析executeCommand函数时，Client发过来的请求中会记录着WMS的BBinder对象地址的原因。

6.7 匿名Binder Server

前一小节我们讨论的WindowManagerService服务，通过addService把自己注册到了Service Manager中，因而任何Binder Client都可以通过SM的getService接口来获取它的一个引用。我们称这种类型的Binder Server为“实名”Server。

而事实上，Android系统中还存在着另一种Binder Server，它们并不在Service Manager中注册——我们称之为“匿名”的Binder Server。匿名性带来的一个直接好处是安全系数的提高，如某个应用程序提供了某种Server服务，但并不希望面向公众开放。显然实名的Server无法避免外界的访问——任何第三方的程序都可以通过Service Manager提供的getService来获取到这一Server。而“匿名”方式的Binder Server则可以很好地解决这一问题。

本小节将以后续显示系统中将会出现的IWindowSession为例来分析“匿名”Server的内部实现。

先来看看IWindowSession的接口文件：

```
/*frameworks/base/core/java/android/view/IWindowSession.aidl*/
interface IWindowSession {
    int add(IWindow window, int seq, in WindowManager.LayoutParam
            in int viewVisibility, out Rect outContentInsets,
            out InputChannel outInputChannel);
     …//其他接口省略
}
```

这个aidl文件经过工具转化后，核心内容如下：

```
public interfaceIWindowSession extends android.os.IInterface
{public static abstract class Stubextends android.os.Binder imple
{
...
@Override public boolean onTransact(int code, android.os.Parcel d
{
switch (code)
{
...
case TRANSACTION_add:
{
```

```
…
}
...
}
return super.onTransact(code, data, reply, flags);
}
private static classProxy implements android.view.IWindowSession
{
private android.os.IBinder mRemote;
...
@Override public int add(…) throws android.os.RemoteException
{
…
}
...
}
static final int TRANSACTION_add =(android.os.IBinder.FIRST_CALL_
...
}
public int add(…) throws android.os.RemoteException;
...
}
```

除了业务处理相关的代码外，它和前一小节的IWindowManager基本上类似，因而此处不再赘述了。我们知道，一个匿名的Binder Server必须借助于其他手段才能被Client访问到。比如IWindowSession就是靠WindowManagerService这一实名Server提供的openSession获取的。代码段如下所示：

```
/*frameworks/base/core/java/android/view/WindowManagerGlobal.java
     public static IWindowSession getWindowSession() {
        synchronized (WindowManagerGlobal.class) {
            if (sWindowSession == null) {//全局变量，用于避免重复操作
                try {
                   …
                   IWindowManager windowManager = getWindowManage
                   sWindowSession = windowManager.openSession(
                      imm.getClient(), imm.getInputContext());//通
                   …
               } catch (RemoteException e) {
                     Log.e(TAG, "Failed to open window session",
               }
           }
           return sWindowSession;
       }
    }
```

Android 4.3中把与WindowManager相关的元素都统一封装到了WindowManagerGlobal.java中，包括上面的IWindowSession。在getWindowSession的实现中，WMS属于实名的Binder Server，因而可以通过调用getWindowManagerServiceIWindowManager.Stub.asInterface(ServiceM getService("window"))来获取到它的本地代理；而IWindowSession则是“匿名”的，它必须经由前者提供的openSession接口来间接地访问到：

```
/*frameworks/base/services/java/com/android/server/wm/WindowManag
    public IWindowSession openSession(IInputMethodClient client,
                                      IInputContext input Cont
        …
        Session session = new Session(this, client, inputContext)
        return session;
    }
```

这个时候Session（它是IWindowSession服务器端的实现）才被真正地创建起来。顺便说一下，在生成Session对象时，同时传入了this指针（即WMS自身），这样后续这个Session对象就可以把从应用程序收到的请求转发给WMS了。

有了这个IWindowSession代理以后，我们就可以像使用其他Binder Server一样获得它的服务了。比如在ensureTouchMode@ViewRootImpl.java中：

```
mWindowSession.setInTouchMode(inTouchMode);
```

最后小结一下：一个匿名Binder Server与实名Server的差异主要就在于后者是通过Service Manager来获得对它的引用；而前者则是以其他实名Server为中介来传递这一引用信息，仅此而已。另外，对于Binder驱动而言，只要是“路过”它且以前没有出现过的Binder对象，都会被记录下来。所以：

- 实名Binder Server

通过addService把Server添加到SM时是它第一次“路过”驱动，因而会被记录到binder_node中，并在SM的进程信息中添加binder_ref引用。这样后面有客户端需要查询时，SM就能准确得出这一Server所在的binder_node位置了。

- 匿名Binder Server

在这个场景中，IWindowSession是靠WMS来传递的；并且要等到Binder Client调用openSession时才真正地生成一个Session对象——这个对象作为reply结果值时会第一次“路过”Binder驱动——此时就会被记录到系统服务进程的proc->nodes中（注意，IWindowSession也存在于系统服务进程中），并且target_proc（也就是ViewRootImpl所在进程）会有一个binder_ref指向这一binder_node节点。

第7章 Android启动过程

7.1 第一个系统进程（init）

Android设备的启动必须经历3个阶段，即Boot Loader、Linux Kernel和Android系统服务，默认情况下它们都有各自的启动界面。

严格来说，Android系统实际上是运行于Linux内核之上的一系列“服务进程”，并不算一个完整意义上的“操作系统”。这些进程是维持设备正常工作的关键，而它们的“老祖宗”就是init。

作为Android中第一个被启动的进程，init的PID值为0。它通过解析init.rc脚本来构建出系统的初始运行形态——其他Android系统服务程序大多是在这个“rc”脚本中描述并被相继启动的。Init.rc不但语法相对简单，而且因为采用了纯文本的编写方式，所以可读性很高，是开发商控制Android系统启动状态的一大“利器”。

接下来首先讲解init.rc脚本的语法规则。

7.1.1 init.rc语法

Google对于init.rc的注解很少，唯一的官方文档可能就是/system/core/init/Readme.txt。所以本小节的分析主要基于两个依据——除了这个Readme文件外，就是init进程的源码实现（与init.rc解析相关的代码大部分集中在Init_parser.c中）。

一个完整的init.rc脚本由4种类型的声明组成，即：

- Action（动作）；
- Commands（命令）；
- Services（服务）；
- Options（选项）。

首先需要了解一些通用的语法规则：

- 注释以井号键（“#”）开头；
- 关键字和参数以空格分隔，每个语句以行为单位；
- C语言风格的反斜杠转义字符（“\”）可以用来为参数添加空格；
- 为了防止字符串中的空格把其切割成多个部分，我们需要对其使用双引号；
- 行尾的反斜杠用来表示下面一行是同一行；
- Actions（动作）和Services（服务）暗示着一个新语句的开始，这两个关键字后面跟着的commands（命令）或者options（选项）都属于这个新语句；
- Actions（动作）和Services（服务）有唯一的名字，如果出现和已有动作或服务重名的，将会被当成错误忽略掉。

接下来详细分析各组成元素。

1．Actions（动作）

动作的一般格式如下：

```
on <trigger> ##触发条件
   <command1> ##执行命令
   <command2>##可以执行多个命令
   <command3>
   …
```

从上面的描述可以知道，一个Action其实就是响应某事件的过程。即当<trigger>所描述的触发事件产生时，依次执行各种command（同一事件可以对应多个命令）。从源码实现的角度来说，当相应的事件发生后，系统会对init.rc中的各<trigger>进行匹配——只要发现符合条件的Action，就会把它加入“命令执行队列”的尾部（除非这个Action在队列中已经存在），然后系统再对这些命令按顺序执行。

2．Commands（命令）

命令将在所属事件发生时被一个个地执行。

表7-1列出了init中定义的一些常见事件。

表7-1　Init.rc中常见触发事件

Trigger	Description
boot	这是init程序启动后触发的第一个事件
<name>=<value>	当属性<name>满足特定<vaule>时触发。后面有关于属性的进一步介绍
device-added-<path> device-removed-<path>	当设备节点添加/删除时触发此事件
service-exited-<name>	当指定的服务<name>存在时触发

针对这些事件，有如表7-2所示命令可供使用。

表7-2　init.rc中的常见命令

Command	Description
exec <path> [<argument>]*	Fork并执行一个程序，其路径为<path>。这条命令将阻塞直到该程序启动完成，因此它有可能造成init程序在某个点不停地等待
export <name> <value>	设置某个环境变量<name>的值为<value>。这是对全局有效的，即其后所有进程都将继承这个变量
ifup <interface>	使网络接口<interface>成功连接
import <filename>	解析另一个配置文件，名为<filename>，以扩展当前配置
hostname <name>	设置主机名为<name>
chdir <directory>	更改工作目录为<directory>
chmod <octal-mode> <path>	更改文件访问权限
chown <owner> <group><path>	更改文件所有者和组群

chroot <directory>	更改根目录位置
class_start <serviceclass>	启动由<serviceclass>类名指定的所有相关服务，如果它们不在运行状态的话
class_stop <serviceclass>	停止所有由<serviceclass>指定的服务，如果它们当前正在运行的话
domainname <name>	设置域名
insmod <path>	在<path>路径上安装一个模块
mkdir <path>[mode] [owner] [group]	在<path>路径上新建一个目录
mount <type> <device><dir> [<mountoption>]*	尝试在指定路径上挂载一个设备
setkey	目前未定义
setprop <name> <value>	设置系统属性<name>的值为<value>
setrlimit <resource> <cur><max>	设置一种资源的使用限制。这个概念亦存在于Linux系统中，<cur>表示软限制，<max>表示硬限制。更多详情请参考Linux资料

start <service>	这个命令将启动一个服务，如果它没有处于运行状态的话
stop <service>	这个命令将停止一个服务，如果它当前正在运行的话
symlink <target> <path>	创建一个<path>路径的链接，目标为<target>
sysclktz <mins_west_of_gmt>	设置基准时间，如果当前时间是GMT，这个值是0
trigger <event>	触发一个事件
write <path><string> [<string>]*	打开一个文件，并写入一个或多个字串

3．Services（服务）

Services其实是可执行程序，它们在特定选项的约束下会被init程序运行或者重启（Service可以在配置中指定是否需要退出时重启，这样当Service出现异常crash时就可以有机会复原）。

它的一般格式为：

```
service <name><pathname> [ <argument> ]*
    <option>
    <option>
    ...
```

- <name>

表示此service的名称。

- <pathname>

此service所在路径。因为是可执行文件，所以一定有存储路径。

- <argument>

启动service所带的参数。

- <option>

对此service的约束选项（后面有详细列表说明）。

4．Options（选项）

Services中的可用选项如表7-3所示。

表7-3　Services中的可用选项

Option	Description
critical	表明这是对设备至关重要的一个服务。如果它在四分钟内退出超过四次，则设备将重启进入恢复模式
disabled	此服务不会自动启动，而是需要通过显式调用服务名来启动
setenv <name> <value>	设置环境变量<name>为某个值<value>
socket <name>	创建一个名为/dev/socket/<name>的unix domain socket，然后将它的fd值传给启动它的进程有效

<type><perm> [<user> [<group>]]	的<type>值包括dgram,stream和seqpacket。而user和group的默认值是0
user <username>	在启动服务前将用户切换至<username>，默认情况下用户都是root
group <groupname> [<groupname>]*	在启动服务前将用户组切换至<groupname>
oneshot	当此服务退出时，不要主动去重启它
class <name>	为该服务指定一个class名。同一个class的所有服务必须同时启动或者停止。默认情况下服务的class名是“default”
onrestart	当此服务重启时，执行某些命令

综合以上的分析会发现，其实init.rc的语法可以用一个统一的形式来理解。如下所示：

```
On<SOMETHING-HAPPENED>
<WHAT-TO-DO>
```

对于Action来说，它是当<trigger>发生时去执行命令；而对于Service来说，它是always发生的（不需要启动触发条件），然后去启动指定的可执行文件（并且由Option来限制执行条件）。

7.1.2 init.rc实例分析

本小节通过分析一个init.rc范例来进一步理解它的语法规则：

```
on boot#boot事件
  export PATH /sbin:/system/sbin:/system/bin  #响应boot事件，设置系纟
  export LD_LIBRARY_PATH /system/lib    #响应boot事件，设置库路径
  mkdir /dev #创建/dev目录
  mkdir /proc #创建/proc目录
  mkdir /sys #创建/sys目录。这时还没有超出on boot的作用范围，下同
  mount tmpfs tmpfs /dev
  mkdir /dev/pts
  mkdir /dev/socket
  mount devpts devpts /dev/pts
  mount proc proc /proc
  mount sysfs sysfs /sys #以上几行用于挂载文件系统以及创建新的目录
  write /proc/cpu/alignment 4 #打开文件，并写入数值
  ifup lo #建立lo网络连接
  hostname localhost #设置主机名
  domainname localhost #设置域名
  mount yaffs2 mtd@system /system
  mount yaffs2 mtd@userdata /data
  import /system/etc/init.conf #导入另一个配置文件
  class_start default #启动所有标志为default的服务
service adbd /sbin/adbd #启动adbd服务进程
  user adb
  group adb # Adbd是android debug bridge daemon的缩写，它为开发者与设
            # 我们将在本书工具篇中对adb进行详细分析。
service usbd /system/bin/usbd -r
  user usbd
  group usbd
  socket usbd 666 #启动usbd服务。
service zygote /system/bin/app_process -Xzygote /system/bin --zyg
  socket zygote 666 #启动zygote服务。Zygote是系统的“孵化器”，负责生产“
on device-added-/dev/compass
  start akmd  #当增加了/dev/compass节点后，启动akmd服务
on device-removed-/dev/compass
  stop akmd #当移除了/dev/compass节点后，停止akmd服务
service akmd /sbin/akmd
  disabled
  user akmd
  group akmd #因为这里对akmd服务使用了disabled选项，所以系统不会主动去启
            #描述的/dev/compass节点出现时，才显式地调用此服务
```

7.2 系统关键服务的启动简析

作为Android系统的第一个进程，init将通过解析init.rc来陆续启动其他关键的系统服务进程——其中最重要的就是ServiceManager、Zygote和SystemServer。

7.2.1 Android的“DNS服务器”——ServiceManager

ServiceManager是Binder机制中的“DNS服务器”，负责域名（某Binder服务在ServiceManager注册时提供的名称）到IP地址（由底层Binder驱动分配的值）的解析。

ServiceManager是在Init.rc里描述并由init进程启动的。如下所示：

```
/*sytem/core/rootdir/Init.rc*/
service servicemanager /system/bin/servicemanager
    class core
    user system
    group system
    critical
    onrestart restart healthd
    onrestart restart zygote
    onrestart restart media
    onrestart restart surfaceflinger
    onrestart restart drm
```

可以看到，servicemanger是一个Linux程序。它在设备中的存储路径是/system/bin/service- manager，源码路径则是/frameworks/native/cmds/servicemanager。

ServiceManager所属class是core，其他同类的系统进程包括ueventd、console(/system/bin/sh)、adbd等。根据core组的特性，这些进程会同时被启动或停止。另外，critical选项说明它是系统的关键进程——意味着如果进程不幸地在4分钟内异常退出超过4次，则设备将重启并进入还原模式。当ServiceManager每次重启时，其他关键进程如Zygote、media、surfaceflinger等也会被restart。

7.2.2 “孕育”新的线程和进程——Zygote

Zygote这个词的字面意思是“受精卵”，因而可以“孕育”出一个“新生命”。正如其名所示，Android中大多数应用进程和系统进程

都是通过Zygote来生成的。

接下来具体分析下Zygote是如何启动的。

和ServiceManager类似，Zygote也是由init解析rc脚本时启动的。早期的Android版本中Zygote的启动命令直接被书写在init.rc中。但随着硬件的不断升级换代，Android系统不得不面对32位和64位机器同时存在的状况，因而，对Zygote的启动也需要根据不同的情况区分对待：

```
/*system/core/rootdir/init.rc*/
import /init.${ro.hardware}.rc
import /init.${ro.zygote}.rc
```

根据系统属性ro.zygote的具体值，我们需要加载不同的描述Zygote的rc脚本。譬如下面是一个典型的例子：

其中zygote32和zygote64分别对应32位和64位机器的情况;而zygote32_64和zygote64_32则是Primary Arch和Secondary Arch的组合。我们以init.zygote64.rc为例，相关代码如下：

```
service zygote /system/bin/app_process64 -Xzygote /system/bin --z
    class main
    socket zygote stream 660 root system
    onrestart write /sys/android_power/request_state wake
    onrestart write /sys/power/state on
    onrestart restart media
    onrestart restart netd
```

从上面这段脚本描述可以看出：

```
ServiceName: zygote
Path: /system/bin/app_process64
Arguments: -Xzygote /system/bin --zygote --start-system-server
```

Zygote所属class为main，而不是core。和其同class的系统进程有netd、debuggerd、rild等。

从zygote的path路径可以看出，它所在的程序名叫“app_process64”，而不像ServiceManager一样在一个独立的程序中。通过指定--zygote参数，app_process可以识别出用户是否需要启动zygote。那么，app_process又是何方神圣呢？

这个命名有些“怪异”的程序源码路径在/frameworks/base/cmds/app_process中，先来看看它的Android.mk：

```
LOCAL_PATH:= $(call my-dir)

include $(CLEAR_VARS)

LOCAL_SRC_FILES:= \
     app_main.cpp

LOCAL_SHARED_LIBRARIES := \
     libcutils \
     libutils \
     liblog \
     libbinder \
     libandroid_runtime

LOCAL_MODULE:= app_process
LOCAL_MULTILIB := both
LOCAL_MODULE_STEM_32 := app_process32
LOCAL_MODULE_STEM_64 := app_process64
include $(BUILD_EXECUTABLE)
```

上述是构建Multilib（64位和32位系统）的一个编译脚本范例。其中LOCAL_MULTILIB用于指示你希望针对的硬件平台架构。可选值如下：

- “32”

  表示只编译32位版本。

- “64”

  表示只编译64位版本。

- “both”

表示同时编译32位和64位的版本。

- “”

表示由系统根据其他变量来决定要编译的目标。

这些知识点我们在本书的编译章节已经做过详细分析，不清楚的读者可以回头复习。

从上面的描述可以很明显地看到，app_process其实扮演了一个类似于“壳”的角色，那么它容纳了哪些“内容”呢？

只要分析一下app_process的主函数实现就知道答案了：

```
/*frameworks/base/cmds/app_process/App_main.cpp*/
int main(int argc, char* const argv[])
{…
    AppRuntime runtime(argv[0], computeArgBlockSize(argc, argv));
    …
    bool zygote = false;
    bool startSystemServer = false;
    bool application = false;
    String8 niceName;
    String8 className;

    ++i;  // Skip unused "parent dir" argument.
    while (i < argc) {
        const char* arg = argv[i++];
        if (strcmp(arg, "--zygote") == 0) { //当前进程是否用于承载zyg
            zygote = true;
            niceName = ZYGOTE_NICE_NAME;
        } else if (strcmp(arg, "--start-system-server") == 0) {//
            startSystemServer = true;
        } else if (strcmp(arg, "--application") == 0) {
            application = true;
        } else if (strncmp(arg, "--nice-name=", 12) == 0) {
            niceName.setTo(arg + 12);
        } else if (strncmp(arg, "--", 2) != 0) {
            className.setTo(arg);
            break;
        } else {
            --i;
            break;
        }
```

```
    }
    …
    if (zygote) {
        runtime.start("com.android.internal.os.ZygoteInit", args)
    } else if (className) {
        runtime.start("com.android.internal.os.RuntimeInit", args
    } else {
        …
    }
}
```

这个函数用于解析启动app_process时传入的参数，具体如下。

--zygote：表示当前进程用于承载zygote。

--start-system-server：是否需要启动system server。

--application：启动进入独立的程序模式。

--nice-name：此进程的“别名”。

对于非zygote的情况下，在上述参数的末尾会跟上main class的名称，而后的其他参数则属于这个class的主函数入参；对于zygote的情况，所有参数则会作为它的主函数入参使用。

在我们这个场景中，init.rc指定了--zygote选项，因而app_process接下来将启动“ZygoteInit”并传入“start-system-server”。之后ZygoteInit会运行于Java虚拟机上，为什么？

原因就是runtime这个变量——它实际上是一个AndroidRuntime对象，其start函数源码如下：

```
/*frameworks/base/core/jni/AndroidRuntime.cpp*/
void AndroidRuntime::start(const char* className, const char* opt
{
    …
    JNIEnv* env;
    if (startVm(&mJavaVM, &env) != 0) {//启动虚拟机
        return;
    }
    onVmCreated(env);//虚拟机启动后的回调
    …
}
```

对于虚拟机的具体启动和运行过程，本书的ART虚拟机一章有详细介绍，请大家参考阅读。我们这里假设VM可以成功启动，并进入ZygoteInit的执行中：

```
/*frameworks/base/core/java/com/android/internal/os/ZygoteInit.ja
public static void main(String argv[]) {
        try {…
            boolean startSystemServer = false;
            String socketName = "zygote";
            String abiList = null;
            for (int i = 1; i < argv.length; i++) {
                if ("start-system-server".equals(argv[i])) {
                   startSystemServer = true;//需要启动System Server
                } else if (argv[i].startsWith(ABI_LIST_ARG)) {
                   abiList = argv[i].substring(ABI_LIST_ARG.lengt
                } else if (argv[i].startsWith(SOCKET_NAME_ARG)) {
                   socketName = argv[i].substring(SOCKET_NAME_ARG
                } else {
                   throw new RuntimeException("Unknown command li
                }
            }

            if (abiList == null) {
                throw new RuntimeException("No ABI list supplied.
            }

            registerZygoteSocket(socketName);//注册一个Socket
          preload();//预加载各类资源
            …
            if (startSystemServer) {
                startSystemServer(abiList, socketName);//后面对此函
            }

            Log.i(TAG, "Accepting command socket connections");
            runSelectLoop(abiList);

            closeServerSocket();
        } catch (MethodAndArgsCaller caller) {
            caller.run();
        } catch (RuntimeException ex) {
            Log.e(TAG, "Zygote died with exception", ex);
            closeServerSocket();
            throw ex;
        }
    }
```

ZygoteInit的主函数并不复杂，它主要完成两项工作：

- 注册一个Socket

Zygote是“孵化器”，一旦有新程序需要运行时，系统会通过这个Socket（完整的名称为ANDROID_SOCKET_zygote）在第一时间通知“总管家”，并由它负责实际的进程孵化过程。

- 预加载各类资源

函数preload用于加载虚拟机运行时所需的各类资源，包括：

```
preloadClasses();
preloadResources();
preloadOpenGL();
preloadSharedLibraries();
```

从名称中相信不难看出上述各个preload函数的作用。以preloadClasses为例，它负责加载和初始化常用的一些classes。这些需要预加载的classes被记录在framework.jar的preloaded-classes中，如下例子所示：

```
# Classes which are preloaded by com.android.internal.os.ZygoteIn
# Automatically generated by frameworks/base/tools/preload/WriteP
java.
# MIN_LOAD_TIME_MICROS=1250
# MIN_PROCESSES=10
android.R$styleable
android.accounts.Account
android.accounts.Account$1
android.accounts.AccountManager
android.accounts.AccountManager$12
android.accounts.AccountManager$13
android.accounts.AccountManager$6
android.accounts.AccountManager$AmsTask
android.accounts.AccountManager$AmsTask$1
android.accounts.AccountManager$AmsTask$Response
android.accounts.AccountManagerFuture
android.accounts.IAccountManager
android.accounts.IAccountManager$Stub
android.accounts.IAccountManager$Stub$Proxy
android.accounts.IAccountManagerResponse
android.accounts.IAccountManagerResponse$Stub
```

```
android.accounts.OnAccountsUpdateListener
…
```

从程序可以看到，preloaded-classes中含有多达数千个classes，而且包括了libcore里的重要基础资源，例如android.system、android.util等。另外，从preloaded-classes文件头中的注释可以看出，这个记录表示通过frameworks/base/tools/preload/WritePreloadedClassFile.java生成的。感兴趣的读者可以自行阅读这个文件了解其中的细节。

- 启动System Server

如果app_process的调用参数中带有“--start-system-server”，那么此时就会通过startSystemServer来启动System Server，我们将在稍后对这个函数进行具体分析。

Zygote在前期主要担任启动系统服务的工作，后期则又担当“程序孵化”的重任。但是Zygote只在init.rc中被启动一次，它如何协调好这两项工作的关系呢？我们可以推断一下，上述的startSystemServer应该会新建一个专门的进程来承载系统服务的运行，而后app_process所在的进程则转变为Zygote的“孵化器”守护进程。那么是不是这样子的呢？

```
/* frameworks/base/core/java/com/android/internal/os/ZygoteInit.j
private static boolean startSystemServer(String abiList, String s
            throws MethodAndArgsCaller, RuntimeException {
        …
        /* Hardcoded command line to start the system server */
        String args[] = {
            "--setuid=1000",
            "--setgid=1000",
            "--setgroups=1001,1002,1003,1004,1005,1006,1007,1008,
                         1032,3001,3002,3003,3006,3007",
            "--capabilities=" + capabilities + "," + capabilities
            "--runtime-init",
            "--nice-name=system_server",
            "com.android.server.SystemServer",
        };
        ZygoteConnection.Arguments parsedArgs = null;

        int pid;
```

```
        try {
            parsedArgs = new ZygoteConnection.Arguments(args);
            ZygoteConnection.applyDebuggerSystemProperty(parsedAr
            ZygoteConnection.applyInvokeWithSystemProperty(parsed

            /* Request to fork the system server process */
            pid = Zygote.forkSystemServer(
                    parsedArgs.uid, parsedArgs.gid,
                    parsedArgs.gids,
                    parsedArgs.debugFlags,
                    null,
                    parsedArgs.permittedCapabilities,
                    parsedArgs.effectiveCapabilities); //果然需要fo
        } catch (IllegalArgumentException ex) {
            throw new RuntimeException(ex);
        }

        if (pid == 0) {//子进程，即System Server所承载进程
            if (hasSecondZygote(abiList)) {
                waitForSecondaryZygote(socketName);
            }

            handleSystemServerProcess(parsedArgs);//启动各System S
        }

        return true;
    }
```

上述代码段又出现了我们熟悉的fork流程——forkSystemServer在内部利用UNIX的fork机制创建了一个新进程；而这个“新生儿”（即pid==0分支）会在随后的执行过程中通过handleSystemServerProcess来启动各种支撑系统运行的System Server。

在跟踪System Server的具体启动过程之前，我们先来为Zygote接下来的工作做一个分析。与我们之前所见的fork处理流程不同的是，startSystemServer中并没有为父进程专门开辟一个代码分支，因而这个函数最后会通过return true而返回到ZygoteInit的主函数中。紧随其后的语句就是：

```
runSelectLoop(abiList);
```

从runSelectLoop的函数名称可以猜到，这很可能会是一个“死循环”——除非Zygote退出或者出现异常才会跳出循环：

```
/* frameworks/base/core/java/com/android/internal/os/ZygoteIn
private static void runSelectLoop(String abiList) throws Meth
    ArrayList<FileDescriptor> fds = new ArrayList<FileDescrip
    ArrayList<ZygoteConnection> peers = new ArrayList<ZygoteC
    FileDescriptor[] fdArray = new FileDescriptor[4];

    fds.add(sServerSocket.getFileDescriptor());
    peers.add(null);//添加null是为了保持fds和peers的一致性

    int loopCount = GC_LOOP_COUNT;//设定多少次循环才调用垃圾回收函
    while (true) {//确实如我们所料，是一个死循环
        int index;
        if (loopCount <= 0) {
            gc();//达到10次循环，做一次gc
            loopCount = GC_LOOP_COUNT;
        } else {
            loopCount--;
        }

        try {
            fdArray = fds.toArray(fdArray);
            index = selectReadable(fdArray);
        } catch (IOException ex) {
            throw new RuntimeException("Error in select()", e
        }

        if (index < 0) {//出错的情况
            throw new RuntimeException("Error in select()");
        } else if (index == 0) {//有新的连接请求
            ZygoteConnection newPeer = acceptCommandPeer(abiL
            peers.add(newPeer);
            fds.add(newPeer.getFileDescriptor());
        } else {//已建立的连接中有客户端发过来的数据需要处理
            boolean done;
            done = peers.get(index).runOnce();

            if (done) {
                peers.remove(index);
                fds.remove(index);
            }
        }
    }
}
```

从程序中可以看到，runSelectLoop的主体的确是一个while死循环，它将作为zygote的守护体存在。因为zygote此时运行在虚拟机环境中，所以它需要考虑垃圾回收的问题。不过这是一项非常耗时的操作，

如果操作过于频繁，每次回收的垃圾并不会很多，那么就得不偿失。所以上述函数中设定了GC_LOOP_COUNT为10，意味着while每循环十次才会调用一次gc()。那么while执行一轮都完成了哪些工作呢？

我们从sServerSocket.getFileDescriptor()获取到的是前面通过registerZygoteSocket创建的Server Socket的文件描述符，它会被添加到一个ArrayList<FileDescriptor>类型的fds变量中。这同时也意味着zygote中不光只有一个Socket产生。具体而言，while循环中会先通过如下两个语句来判断当前哪个fd处于可读状态：

```
fdArray = fds.toArray(fdArray);
index = selectReadable(fdArray);
```

当fds这个ArrayList指示的某个文件有可读数据时，返回的index值就代表此文件对应的file descriptor在队列中的序列。另外，这个函数还有一个特殊的返回值：0。因为fds中的第一个元素为Zygote的Server Socket，所以index为0代表了有新的连接请求。这和网络连接中的Socket概念是一致的。

- index ==0

此时我们需要通过acceptCommandPeer来接受来自客户端的连接，产生一个新的Zygote Connection，然后分别更新peers和fds。为了保证这两个列表中的对象序列号保持一致，可以看到peers在初始化时专门添加了一个null，对应的是Zygote Server Socket这个“监听者”

- index >0

此时说明已经建立的Socket连接中有来自客户端的数据需要处理，完成具体工作的是runOnce，下面我们详细分析一下这个函数：

```
/*frameworks/base/core/java/com/android/internal/os/ZygoteConne
boolean runOnce() throws ZygoteInit.MethodAndArgsCaller {
      String args[];
      Arguments parsedArgs = null;
      FileDescriptor[] descriptors;
      …
      try{…
          checkTime(startTime, "zygoteConnection.runOnce: preFo
          pid = Zygote.forkAndSpecialize(parsedArgs.uid, parsed
```

```
                                        parsedArgs.gids, parsedArgs.de
                                     parsedArgs.mountExternal, parsedA
                    parsedArgs.niceName, fdsToClose, parsedArgs.ins
                    parsedArgs.appDataDir);
            checkTime(startTime, "zygoteConnection.runOnce: postF
        } catch (IOException ex) {
            logAndPrintError(newStderr, "Exception creating pipe"
        } catch (ErrnoException ex) {
            logAndPrintError(newStderr, "Exception creating pipe"
        } catch (IllegalArgumentException ex) {
            logAndPrintError(newStderr, "Invalid zygote arguments
        } catch (ZygoteSecurityException ex) {
            logAndPrintError(newStderr,
                    "Zygote security policy prevents request: ",
        }

        try {
            if (pid == 0) {
                // in child
                IoUtils.closeQuietly(serverPipeFd);
                serverPipeFd = null;
                handleChildProc(parsedArgs, descriptors, childPip
                return true;
            } else {
                IoUtils.closeQuietly(childPipeFd);
                childPipeFd = null;
                return handleParentProc(pid, descriptors, serverP
            }
        } finally {
            IoUtils.closeQuietly(childPipeFd);
            IoUtils.closeQuietly(serverPipeFd);
        }
    }
```

这个函数比较长，其中有两个地方需要我们重点关注：

- 创建承载应用程序的新进程

这是在意料之中的，zygote需要为每个新启动的应用程序生成自己独立的进程。不过runOnce中并没有直接使用fork来完成这一工作，而是调用了forkAndSpecialize，我们稍后会分析这个函数的实现。另外，新创建的进程中一定需要运行应用程序本身的代码，这一部分工作是在handleChildProc中展开的。

- 父进程的“扫尾”工作

执行完上述的任务后，父进程还需要做一些清尾工作才算“大功告成”。包括：将子进程加入进程组；正确关闭文件；调用方返回结果值等。

Specialize的字面意思是“专门化”，表达了forkAndSpecialize在“孵化”的同时也把它转变为Android应用程序的目标。函数forkAndSpecialize的处理分为3个阶段，即preFork、nativeForkAndSpecialize以及postForkCommon：

```
/*frameworks/base/core/java/com/android/internal/os/Zygote.java*/
public static int forkAndSpecialize(int uid, int gid, int[] gids,
        int[][] rlimits, int mountExternal, String seInfo, String
        int[] fdsToClose, String instructionSet, String appDataDi
      long startTime = SystemClock.elapsedRealtime();
      VM_HOOKS.preFork();
      checkTime(startTime, "Zygote.preFork");
      int pid = nativeForkAndSpecialize(
              uid, gid, gids, debugFlags, rlimits, mountExternal,
              fdsToClose, instructionSet, appDataDir);
      checkTime(startTime, "Zygote.nativeForkAndSpecialize");
      VM_HOOKS.postForkCommon();
      checkTime(startTime, "Zygote.postForkCommon");
      return pid;
   }
```

中间过程限于篇幅我们不去深究，接下来直接分析preFork在Zygote中对应的实现：

```
/*art/runtime/native/dalvik_system_ZygoteHooks.cc*/
static jlong ZygoteHooks_nativePreFork(JNIEnv* env, jclass) {
  Runtime* runtime = Runtime::Current();
  CHECK(runtime->IsZygote()) << "runtime instance not started wit
  runtime->PreZygoteFork();
  // Grab thread before fork potentially makes Thread::pthread_ke
  Thread* self = Thread::Current();
  return reinterpret_cast<jlong>(self);
}
```

这里的Runtime实例具体而言指的是Zygote进程中的运行环境，我们在本书虚拟机章节中会有详细分析。而runtime→PreZygoteFork又会间接调用Heap::PreZygoteFork，从而完成堆空间的初始操作。

函数nativeForkAndSpecialize是一个native方法，具体对应的实现是com_android_internal_os_Zygote_nativeForkAndSpecialize，后者则又进一步调用了ForkAnd SpecializeCommon：

```
/*frameworks/base/core/jni/com_android_internal_os_Zygote.cpp*/
static pid_t ForkAndSpecializeCommon(JNIEnv* env, uid_t uid, gid_
                                     jintArray javaGids,
                                     jint debug_flags, jobjectArr
                                     jlong permittedCapabilities,
                                     jlong effectiveCapabilities,
                                     jint mount_external,
                                     jstring java_se_info, jstrin
                                     bool is_system_server, jintA
                                     jstring instructionSet, jstr
  uint64_t start = MsTime();
  SetSigChldHandler();
  ckTime(start, "ForkAndSpecializeCommon:SetSigChldHandler");

  pid_t pid = fork();//这里才真正孵化出一个新进程

  if (pid == 0) {…//子进程中

    env->CallStaticVoidMethod(gZygoteClass, gCallPostForkChildHoo
                              is_system_server ? NULL : instructi
    …
  } else if (pid > 0) {
    //父进程，这里什么也不做，因为runOnce中有处理
  }
  return pid;
}
```

这个函数首先会fork一个新进程，并在pid==0这一分支中为孵化的进程完成一系列初始化操作，而后执行CallStaticVoidMethod。其中gZygoteClass对应的是“com/android/internal/os/Zygote”，而gCallPostForkChildHooks则是Zygote这个类中的成员函数callPostForkChildHooks——从名称可以看出用于执行孵化后的一些处理工作。ForkAndSpecializeCommon也还没有涉及与应用程序相关的具体业务，这部分工作会由runOnce中的handleChildProc来完成，核心代码如下：

```
/*frameworks/base/core/java/com/android/internal/os/ZygoteConnect
private void handleChildProc(Arguments parsedArgs,
         FileDescriptor[] descriptors, FileDescriptor pipeFd, Pri
         throws ZygoteInit.MethodAndArgsCaller {…
```

```
    if (parsedArgs.niceName != null) {//子进程的别名
       Process.setArgV0(parsedArgs.niceName);
    }

    if (parsedArgs.runtimeInit) {…
    } else {//应用程序的ActivityThread将在这里被执行
        String className;
        try {
            className = parsedArgs.remainingArgs[0];//实际对应的
        } catch (ArrayIndexOutOfBoundsException ex) {
            logAndPrintError(newStderr,
                   "Missing required class name argument", null
            return;
        }

        String[] mainArgs = new String[parsedArgs.remainingArgs
        System.arraycopy(parsedArgs.remainingArgs, 1,
               mainArgs, 0, mainArgs.length);//className主函数的
        
        if (parsedArgs.invokeWith != null) {…//invoke-with的情况
        } else {
            ClassLoader cloader;
            if (parsedArgs.classpath != null) {
                cloader = new PathClassLoader(parsedArgs.classp
                        ClassLoader.getSystemClassLoader());
            } else {
                cloader = ClassLoader.getSystemClassLoader();
            }

            try {//执行main函数
                ZygoteInit.invokeStaticMain(cloader, className,
            } catch (RuntimeException ex) {
                logAndPrintError(newStderr, "Error starting.",
            }
        }
    }
  }
```

这个函数的任务用一句话来概况，就是找到并执行目标进程的入口函数。Android系统中所有应用程序理论上都是由Zygote启动的；而且从本小节的分析中，我们不难发现Zygote会为新启动的应用程序fork一个进程。不过和传统的内核中的fork+exec的作法不同的地方是，Zygote中并不会执行exec()。这在某些情况下就会造成一些障碍，比如无法使用valgrind来监测程序的内存泄露情况。为了响应开发人员的类似需求，Android系统特别提供了一种Wrapper实现，并通过

parsedArgs.invokeWith来加以控制。有兴趣的读者可以自行搜索相关资料了解其中的详情。

在handleChildProc这个函数中，最重要的参数之一是className。可以看到，handleChildProc会把className对应的类加载到内存中，然后执行其中的main函数。那么这个className具体是指什么呢？

要回答这个问题并不是件容易的事，需要大家对应用程序的启动流程有一个全局的认识。本书的其他章节对此有详细介绍，有需要的读者可以穿插阅读。我们这里假设当前流程已经到了ActivityManagerService，它会向Zygote发起一个创建新进程的请求，如下所示：

```
/*frameworks/base/services/core/java/com/android/server/am/Activi
 private final void startProcessLocked(ProcessRecord app, String
          String hostingNameStr, String abiOverride, String entry
          String[] entryPointArgs) {…
   Process.ProcessStartResult startResult = Process.start(entryPo
                 app.processName, uid, uid, gids, debugFlags, mou
                 app.info.targetSdkVersion, app.info.seinfo,
                 requiredAbi, instructionSet,
              app.info.dataDir, entryPointArgs);//这些参数将被转化为
   …
```

Process的字面意思虽然是进程，但其实它只属于“进程类”，或者称为“进程管家”会贴切些。Process.start显然是去启动一个新的进程以承载业务，而函数的第一个参数entryPoint，即我们在handleChildProc中看到的className。这是因为ActivityManagerService传递过来的字符串形式的参数列表会被Arguments.parseArgs解析成Arguments中的各成员变量，比如表7-4所示。

表7-4　各成员变量

参 数 格 式	对应的成员变量
"--setuid="	uid

"--setgid="	gid
"--target-sdk-version="	targetSdkVersion
"--runtime-init"	runtimeInit
"-classpath"	classpath
"--nice-name="	nicename
剩余的参数	remainingArgs

className对应的是表7-1中的remainingArgs[0]。

现在问题转化为，ActivityManagerService中的entryPoint是如何得来的呢？它的来源简单来讲就是下面这个语句：

```
if (entryPoint == null) entryPoint = "android.app.ActivityThread"
```

换句话说，Zygote中主动执行的类是ActivityThread，这同时也是我们熟知的Android应用程序的“主线程”：

```
/*frameworks/base/core/java/android/app/ActivityThread.java*/
public static void main(String[] args) {…
        Looper.prepareMainLooper();

        ActivityThread thread = new ActivityThread();
        thread.attach(false);

        if (sMainThreadHandler == null) {
            sMainThreadHandler = thread.getHandler();
        }

        AsyncTask.init();
```

```
        Looper.loop();

        throw new RuntimeException("Main thread loop unexpectedly
    }
```

上述的代码段我们在本书操作系统基础知识章节已经接触过了，这里再一次列出来，以便大家可以把各知识点“串联”起来。

到目前为止，我们已经分析了Zygote作为守护进程时，如何为Android应用程序的启动而服务的。在本小节剩余的内容中，大家将学习到它另一方面的工作，即引导系统各重要服务的启动过程。

从前面的分析可以知道，System Server的启动是在startSystemServer中完成的。Zygote首先会利用Zygote.forkSystemServer来孵化出一个子进程，然后在pid==0的分支中调用handleSystem ServerProcess，后者在函数的末尾又会进一步调用RuntimeInit.zygoteInit：

```
/*frameworks/base/core/java/com/android/internal/os/RuntimeInit.j
public static final void zygoteInit(int targetSdkVersion, String[
ClassLoader classLoader) throws ZygoteInit.MethodAndArgsCaller {…
        commonInit();
        nativeZygoteInit();

        applicationInit(targetSdkVersion, argv, classLoader);
    }
```

函数zygoteInit通过3个方面来完成初始化，分别是：

- commonInit

通用部分的初始化，包括设置默认的uncaught exception handler（具体对应的是RuntimeInit中的UncaughtHandler类）；为HttpURLConnection准备好默认的HTTP User-Agent（User Agent包含了与系统浏览器相关的一系列信息，如“Dalvik/1.1.0 (Linux; U; Android Eclair Build/MASTER)”.);开启trace模式（只在emulator下才有必要）等。

- nativeZygoteInit

这是一个本地初始化函数，也是zygoteInit中的重点，我们稍后做

重点分析。

- applicationInit

这个函数的声明为：private static void applicationInit(int targetSdkVersion, String[] argv, Class Loader classLoader);从中可以看出它是程序运行的“起点”。在我们这个场景中，程序指的是System Servers，而“入口”是什么呢？这就和第二个参数argv有关系。这个String[]实际上包含了两个重要的成员变量，即startClass和startArgs。而这两个变量的赋值可以追溯到startSystemServer中，具体代码如下：

```
        String args[] = {
            "--setuid=1000",
            "--setgid=1000",
            "--setgroups=1001,1002,1003,1004,1005,1006,1007,1008,
               1009,1010,1018,1032,3001,3002,3003,3006,3007",
            "--capabilities=" + capabilities + "," + capabilities
            "--runtime-init",
            "--nice-name=system_server",
            "com.android.server.SystemServer",
        };
```

换句话说，startClass对应的就是com.android.server.SystemServer。因而applicationInit最终将调用main@SystemServer：

```
    public static void main(String[] args) {
        new SystemServer().run();
    }
```

经过上面的初始化后，程序现在会有两个分支，其一是nativeZygoteInit主导的本地系统服务的启动；另一个则是applicationInit负责的Java层系统服务的启动。

（1）本地系统服务的启动

在JNI机制中，Native函数在Java层会有一个声明，然后在本地层得到真正的实现。那么当我们调用了Java层的函数后，系统是如何找到Native中与之对应的函数的呢？通常情况下，Native中的C++文件命名是以Java层的package为基础的，如Java层的包名为

com.android.internal.XX，那么其对应的JNI层文件则是com_android_internal_XX。不过这种对应关系并不是绝对不变的，可以根据开发人员的需求进行调整。譬如我们上面的ZygoteInit所在的Java包是com.android. internal.os，而实际上JNI的实现则为AndroidRuntime.cpp。开发人员一定要学会这其中的规则，才能快速找到自己所需的资源。

AndroidRuntime表明这个class的任务是“负责Android的运行时环境”。当我们调用了nativeZygoteInit后，实际上是执行了com_android_internal_os_RuntimeInit_nativeZygoteInit@AndroidRuntime.cpp，如下所示：

```
static void com_android_internal_os_RuntimeInit_nativeZygoteInit(
{
    gCurRuntime->onZygoteInit();
}
```

全局变量gCurRuntime是一个AndroidRuntime的对象，结合本节前面内容的学习，大家应该能想到实际上AndroidRuntime是一个父类，真正的实现则在App_main.cpp中的AppRuntime。当我们新建AppRuntime对象时，它的父类的构造函数会被调用，并为gCurRuntime赋值。上述的onZygoteInit也在这个App_main.cpp文件中，如下所示：

```
/*frameworks/base/cmds/app_process/App_main.cpp*/
virtual void onZygoteInit()
    {…
        sp<ProcessState> proc = ProcessState::self();
        ALOGV("App process: starting thread pool.\n");
        proc->startThreadPool();
    }
```

上面这段代码是Binder机制中的重要组成部分，其中startThreadPool将开启Binder线程池以保证其他进程可以正确访问到Zygote所提供的服务。Zygote通过JNI和回调的方式非常巧妙地把本地层和Java层、SystemServer和app process关联起来了。

关于Binder的更多信息，请大家参考本书相关章节的详细分析。

（2）Java层系统服务的启动

Java层的系统服务比较多，它们各司其职，缺一不可。我们知道，

Zygote会为System Server的运行启动和初始化虚拟机，并通过入口main@SystemServer.java开启“系统服务之旅”。不过main函数只起到“门”的作用，它又会直接调用SystemServer().run()，后者才是真正实现服务的地方：

```
/*frameworks/base/services/java/com/android/server/SystemServer.j
private void run() {…
        SystemProperties.set("persist.sys.dalvik.vm.lib.2",
          VMRuntime.getRuntime().vmLibrary());
        …
        android.os.Process.setThreadPriority(
                android.os.Process.THREAD_PRIORITY_FOREGROUND);
        android.os.Process.setCanSelfBackground(false);
        Looper.prepareMainLooper();//准备主循环体

        // Initialize native services.
        System.loadLibrary("android_servers");//加载本地服务库
        nativeInit();//本地服务初始化

        …

        // Initialize the system context.
        createSystemContext();

        // Create the system service manager.
        mSystemServiceManager = new SystemServiceManager(mSystemC
        LocalServices.addService(SystemServiceManager.class, mSys

        // Start services.
        try {
            startBootstrapServices();
            startCoreServices();
            startOtherServices();//分别启动各种类型的System Server
        } catch (Throwable ex) {…
        }
        …
        Looper.loop();//进入死循环，直到设备关机
        throw new RuntimeException("Main thread loop unexpectedly
    }
```

System Server在启动前首先需要做很多初始化设置，包括将VM的版本记录到系统变量中，设置线程优先级，设置堆的使用率等。我们知道，Android系统服务会被分为两类，其一是Java层的，其二是本地层的。后者具体是由System.loadLibrary("android_servers")实现的，而Java层的服务将在下一小节做重点分析。

通过以上讲解，我们可以看到app_process就是系统服务的“根据地”。它在init进程的帮助下，通过Zygote逐步建立起各SystemServer的运行环境，继而为上层的“繁殖壮大”提供“土壤环境”。

图7-1对本小节所涉及内容进行了总结。

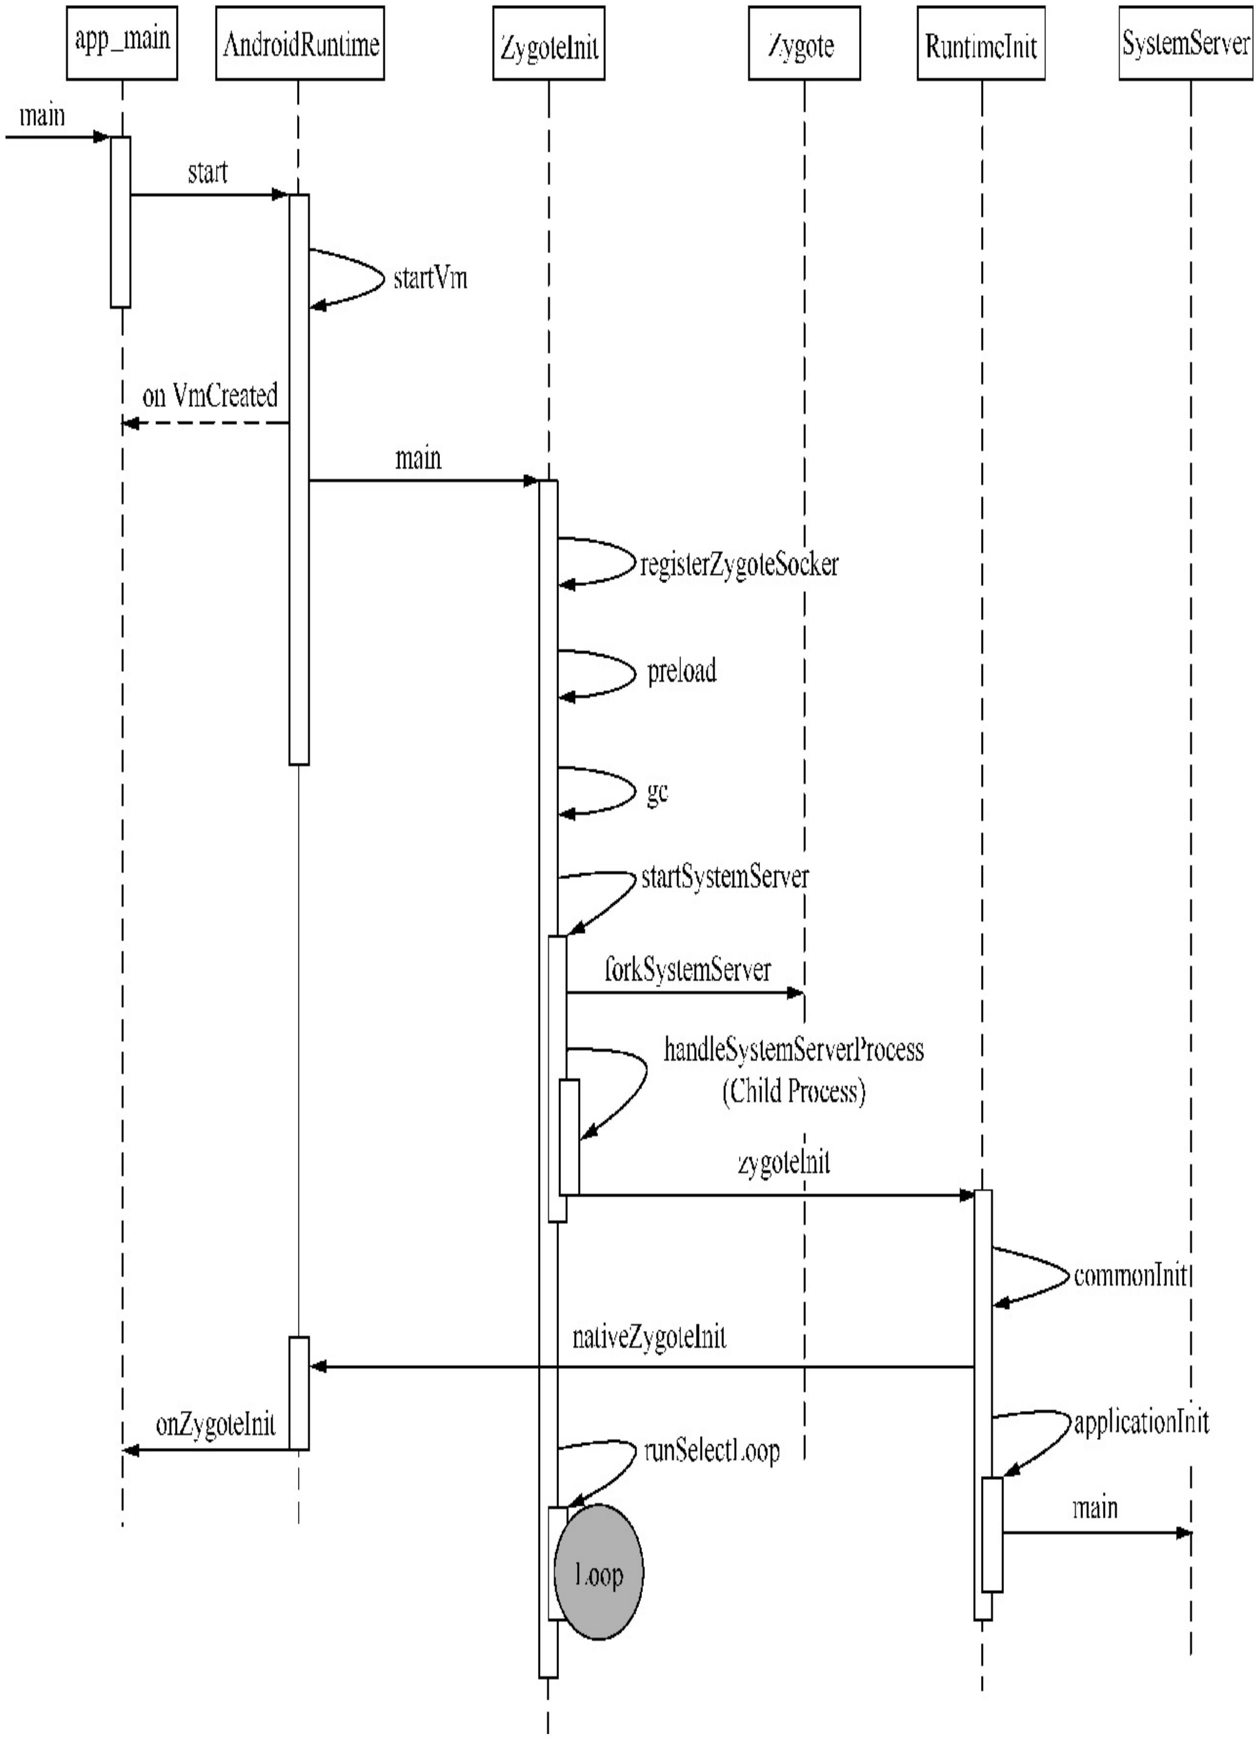

app_main
AndroidRuntime
ZygoteInit
Zygote
RuntimeInit
SystemServer
main
start
startVm
on VmCreated
main
registerZygoteSocker
preload
gc
startSystemServer
forkSystemServer
handleSystemServerProcess
(Child Process)
zygoteInit
commonInit
nativeZygoteInit
onZygoteInit
applicationInit
runSelectLoop
main
Loop

▲图7-1 Zygote和System Server的启动流程

7.2.3 Android的“系统服务”——SystemServer

SystemServer是Android进入Launcher前的最后准备。由其名称就可看出，它提供了众多由Java语言编写的“系统服务”。

由上一小节的学习可知，一旦我们在init.rc中为Zygote指定了启动参数--start-system-server，那么ZygoteInit就会调用startSystemServer来进入SystemServer。而且系统服务又分别分为Java层和本地层两类。其中Native层服务的实现体在android_servers中，需要在run@SystemServer中首先通过System.loadLibrary("android_servers")加载到内存中才能使用。而nativeInit则负责为启动本地层服务而努力。这部分实现在Android的历版变迁中改动不小，特别是对两类系统服务的管辖范围有不小差异。以最新的Android版本而言，它实际上在本地层只留下Sensor服务了：

```
/*frameworks/base/services/core/jni/com_android_server_SystemServ
static void android_server_SystemServer_nativeInit(JNIEnv* env, j
    char propBuf[PROPERTY_VALUE_MAX];
    property_get("system_init.startsensorservice", propBuf, "1");
    if (strcmp(propBuf, "1") == 0) {
        // Start the sensor service
        SensorService::instantiate();
    }
}
```

上述代码段用于SensorService的启动和初始化。Android系统中的Sensor可以理解为比较小的硬件器件，如光线、陀螺仪、重力感应等。它们在属性特征上相对一致，而在数据量上则普遍不大。传统的Android模拟器对其中一些Sensor实现了简单的模拟，功能有限。市面上也有一些厂商为了便于开发者调测应用程序，推出了专门的器件模拟功能，而且与IDE进行了“无缝集成”。大家有兴趣的话可以自行上网搜索了解。

我们再回到Java层来看一下这类系统服务是如何管理的。从代码中可以看到，这部分Server又可细分为3类，如下所示：

- Bootstrap Services

BootStrap的原意是“引导程序”，用在这里则代表系统服务中最核心的那一部分。另外，这些Services间相互的依赖关系比较强，因而需要在一起统一管理启动，具体对应的是startBootstrapServices这个函数。按照Android的建议，如果你自己添加的系统服务和它们也有较强的依赖，那么可以与这类系统服务统一放置，否则就应该考虑下面所述的另两类服务：

```
/*frameworks/base/services/java/com/android/server/SystemServer.j
 private void startBootstrapServices() {
        mInstaller = mSystemServiceManager.startService(Installer
        mActivityManagerService = mSystemServiceManager.startServ
                ActivityManagerService.Lifecycle.class).getServic
        mActivityManagerService.setSystemServiceManager(mSystemSe
        mPowerManagerService = mSystemServiceManager.startService
        mActivityManagerService.initPowerManagement();
        mDisplayManagerService = mSystemServiceManager.startServi
        mSystemServiceManager.startBootPhase(SystemService.PHASE_

        // Only run "core" apps if we're encrypting the device.
        String cryptState = SystemProperties.get("vold.decrypt");
        if (ENCRYPTING_STATE.equals(cryptState)) {
            Slog.w(TAG, "Detected encryption in progress - only p
            mOnlyCore = true;
        } else if (ENCRYPTED_STATE.equals(cryptState)) {
            Slog.w(TAG, "Device encrypted - only parsing core app
            mOnlyCore = true;
        }

        // Start the package manager.
        Slog.i(TAG, "Package Manager");
        mPackageManagerService = PackageManagerService.main(mSyst
                mFactoryTestMode != FactoryTest.FACTORY_TEST_OFF,
        mFirstBoot = mPackageManagerService.isFirstBoot();
        mPackageManager = mSystemContext.getPackageManager();

        Slog.i(TAG, "User Service");
        ServiceManager.addService(Context.USER_SERVICE, UserManag

        // Initialize attribute cache used to cache resources fro
        AttributeCache.init(mSystemContext);

        // Set up the Application instance for the system process
        mActivityManagerService.setSystemProcess();
    }
```

大家应该注意到了，上面的函数中被调用最多的语句是mSystemServiceManager.startService。这和旧版本Android系统中服务“各自为政”的做法有不小差异，换句话说，目前所有System Service都统一由SystemServiceManager来管理。

System Service Manager首先会启动Installer，这是为了让Installer可以优先完成初始化，并完成关键目录（如/data/user）的创建。这些都是其他服务可以顺利启动的先决条件。接下来启动的系统服务是ActivityManagerService，我们在其他章节会做专门的分析，这里先不赘述。

在AMS之后相继启动的服务包括电源管理Power Manager、Display Manager、PackageManager等，最后调用setSystemProcess来添加进程相关的服务，如meminfo、gfxinfo、dbinfo、cpuinfo等，从而完成最核心部分系统服务的启动。

- Core Services

Core Service相对于BootStrap的优先级略低，主要包括LED和背光管理器、电池电量管理器、应用程序使用情况（Usage Status）管理器等。

- Other Services

这部分服务在3类Service中优先级最低，但数量却最多。比如AccountManagerService、VibratorService、MountService、NetworkManagementService、NetworkStatsService、ConnectivityService、WindowManagerService、UsbService、SerialService、AudioService等。这些服务全面构筑起Android系统这座“参天大厦”，为其他进程、应用程序的正常运行奠定了基础。

最后，SystemServer通过Looper.loop()进入长循环中，并依托onZygoteInit中启动的Binder服务接受和处理外界的请求——Android系统的“万里长征”终于开始了。

7.2.4 Vold和External Storage存储设备

和iOS不同的是，Android系统支持多种存储设备，包括外置的

SDCARD、U盘等。这些存储设备的管理机制在不同的Android版本中差异很大，我们将在本小节做一个简单的介绍。

Android系统中的内/外存储设备定义如下：

- Internal Storage

按照Android的设计理念，Internal Storage代表的是/data存储目录。所以目前不少文件管理器事实上混淆了Internal Storage的概念，请大家特别注意。

- External Storage

所有除Internal Storage之外的可存储区域，参见下面的详细描述。

从物理设备的角度来看，External Storage由如下几种类型组成：

- Emulated Storage

Android设备中存在的一个典型做法，是从Internal Storage（如Flash）中划分一定的区域（如1GB）来作为外部存储设备，称为Emulated Storage

- SDCARD/USB Devices

通过扩展卡槽或者USB端口来扩展设备的存储能力，也是Android设备中的常见情况。

另外在某些场合，Android 6.0之前的External Storage会被称为Traditional Storage，从这个角度看它又可以细分成emulated和portable storage两个类型。Portable顾名思义就是指那些没有和系统绑定在一起的，可以随时移除的设备。正是由于这类设备的“暂时性和不稳定性”，它们并不适合用于存储一些敏感数据，例如系统代码、应用程序数据等。Android 6.0则引入了一种叫做“Adoptable Storage”的存储概念，简单来说就是让外部设备可以像内部设备一样被处理。

为了达到上述的效果，被“adopted”的存储设备需要格式化并经过加密过程，以保证数据的安全性。当然，系统会在用户插入新的外部设备时首先询问是否要把它变为adoptable storage。如果答案是肯定的才会执行这些处理；否则还是把它当成普通的存储设备，如图7-2所示。

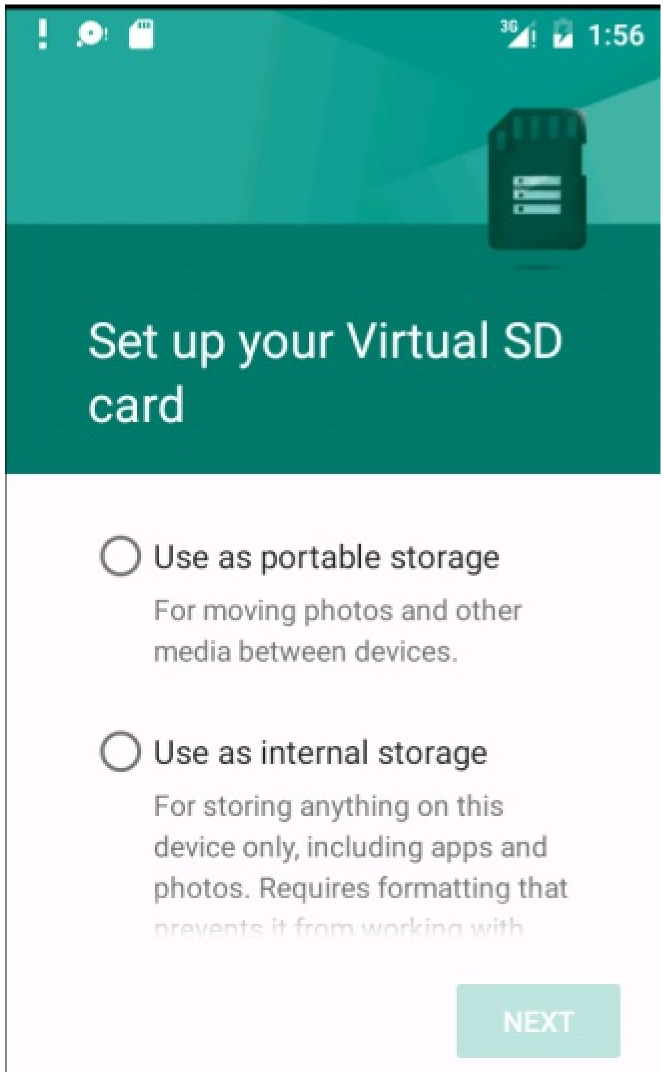

▲图7-2 存储设备

Android系统中的外部存储设备由Vold和Mount Service来统一管理。其中Vold对应的源码路径是：AOSP/system/vold。它是通过init.rc启动的，如下所示：

```
on post-fs-data
…
```

start vold

值得一提的是FUSE services也不再放在init.rc中统一加载，而改由vold根据具体情况来动态决定是否需要启动。

Vold在启动以后，会通过NETLINK和内核取得联系，并根据后者提供的event来构建存储设备管理系统。和以往版本不同的是，Vold的配置文件不再是vold.fstab，而变成了/fstab.<ro.hardware>。例如AOSP/device/fugu/fstab.fugu：

```
/dev/block/by-name/system   /system    ext4    ro,noatime                                                       wait
/dev/block/by-name/cache    /cache     ext4    nosuid,nodev,noatime,barrier=1,data=ordered                      wait,check
/dev/block/by-name/userdata /data      ext4    nosuid,nodev,noatime,discard,barrier=1,data=ordered,noauto_da_alloc wait,check
/dev/block/by-name/factory  /factory   ext4    nosuid,nodev,noatime,barrier=1,data=ordered           wait
/dev/block/by-name/misc     /misc      emmc    defaults                                    defaults
/dev/block/zram0       none       swap    defaults                                   zramsize=104857600
/devices/*/dwc3-host.2/usb* auto       auto    defaults                                    voldmanaged=usb:auto,encryptable=userdata
```

Android 6.0及以后版本中，根据设备具体情况不同主要有如下几种典型配置：

（1）Emulated primary only

即只有Emulated Storage的情况，此时fstab.device的配置范例如下：

```
/devices/*/xhci-hcd.0.auto/usb* auto auto defaults
                                     voldmanaged=usb:auto
```

（2）Physical primary only

即只有一个外置物理存储设备的情况，此时fstab.device的配置范例如下：

```
/devices/platform/mtk-msdc.1/mmc_host* auto auto defaults
voldmanaged=sdcard0:auto,encryptable=userdata,noemulatedsd
```

（3）Emulated primary，physical secondary

有两个外置的物理存储设备，它们会被分别设定为primary和secondary，此时fstab.device的配置范例如下：

```
/devices/platform/mtk-msdc.1/mmc_host* auto auto defaults
voldmanaged=sdcard1:auto,encryptable=userdata
```

fstab的语法规则如下：

```
<src> <mnt_point> <type> <mnt_flags> <fs_mgr_flags>
```

src：在sysfs文件系统下用于描述设备的节点的路径。

mnt_point：设备挂载点。

type：文件系统类型。

mnt_flags：最新版本的vold会忽略这一项。

fs_mgr_flags：对于没有包含“voldmanaged=”的一律会被忽略，换句话说“voldManaged”表示的是它可以被vold管理。

Vold在启动过程中会通过process_config函数来处理fstab配置文件，并把它们存储在VolumeManager的全局变量中。后续当收到内核的NetlinkEvent（add)时，VolumeManager再在handleBlockEvent中根据规则判断本次事件是否和之前记录的fstab配置相匹配——如果答案是肯定的话，则新创建一个Disk对象来管理，并将它们统一添加到mDisks中，如图7-3所示。

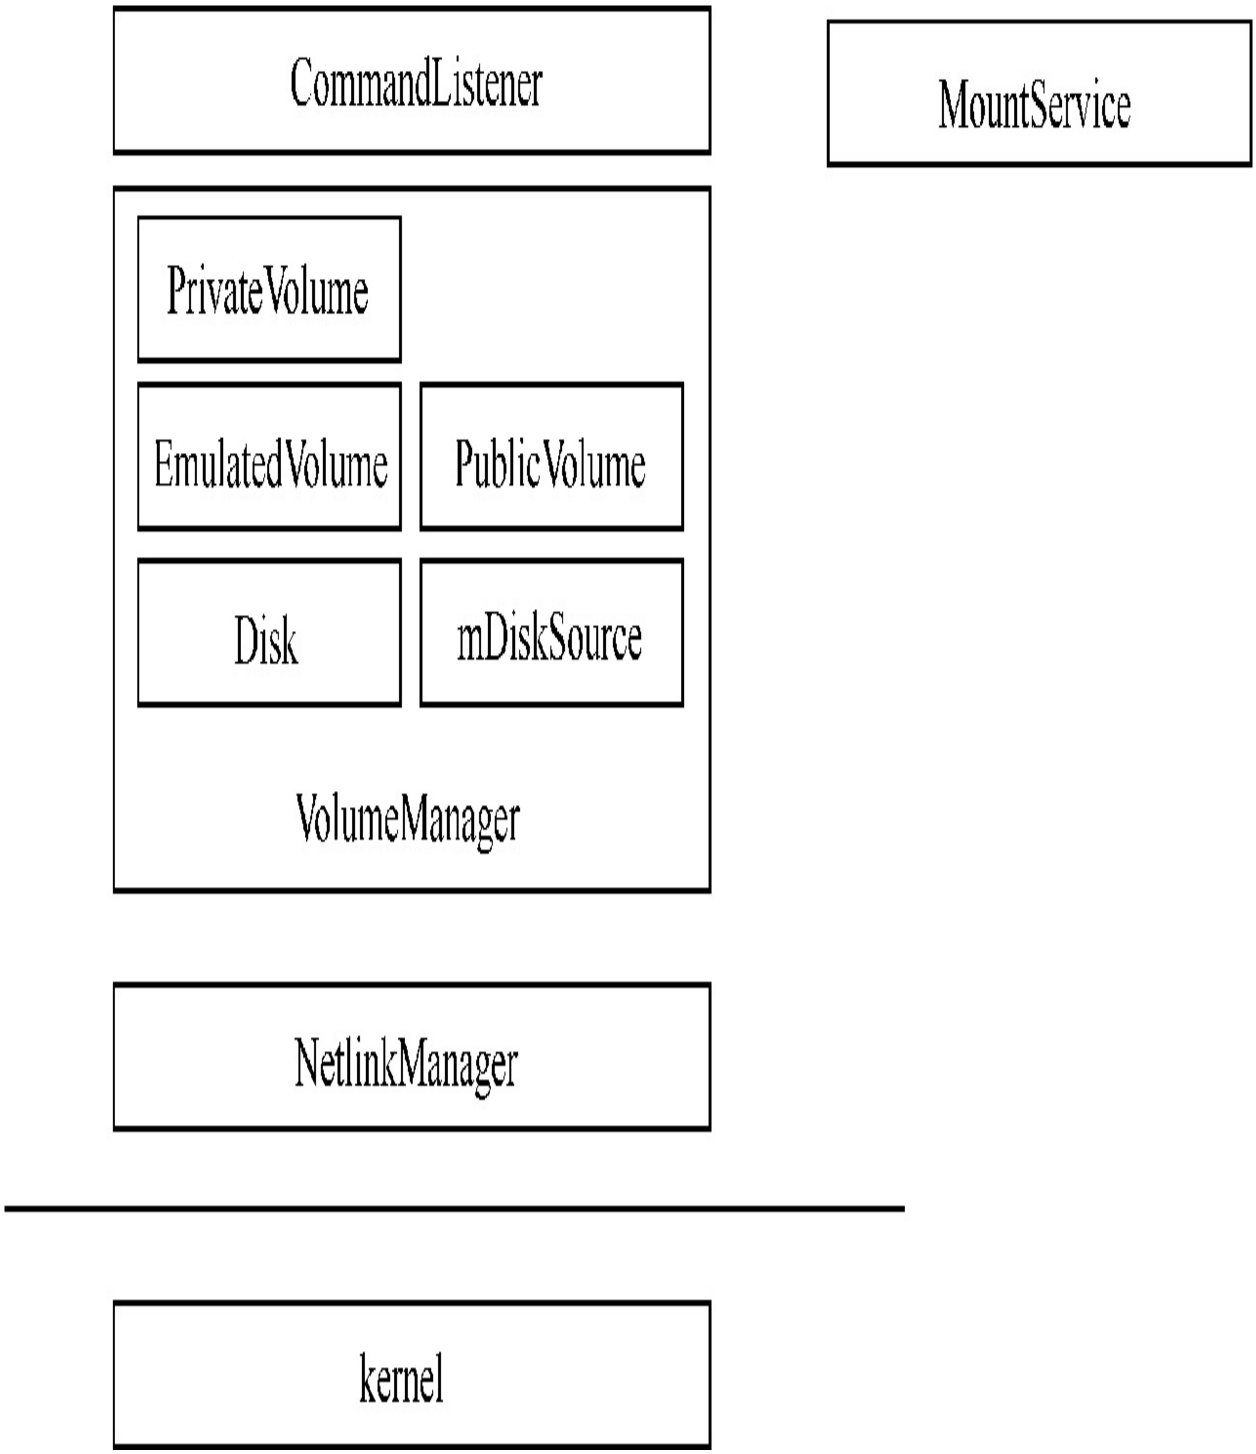

▲图7-3　Vold框架简图

我们不难发现，Emulated Storage所需的存储空间来源于设备的data分区。换句话说，Emulated Storage的存储空间和data分区是共享存储区域的。Emulated Storage当然也是由Volume Manager来统一管理

的，如下所示：

```
/*system/vold/VolumeManager.cpp*/
int VolumeManager::start() {…
    CHECK(mInternalEmulated == nullptr);
    mInternalEmulated = std::shared_ptr<android::vold::VolumeBase
             new android::vold::EmulatedVolume("/data/media"));
    mInternalEmulated->create();
    return 0;
}
```

VolumeManager::start会被vold的main函数调用，因而从Vold的角度来看所有Android设备都是带有Emulated Storage的，只不过最终是否需要执行mount操作则由MountService来决定。从EmulatedVolume构造函数的参数可以看到，它在data分区中对应的路径是/data/media。VolumeManager的全局变量mInternalEmulated用于记录系统的Emulated Storage。

接下来mInternalEmulated->create()除了给Storage创建运行环境外，还会向MountService发送一个VolumeCreated的消息，并将自身的状态迁移到kUnmounted。MountService收到这一信息后，会根据系统的实际情况决定是否挂载这个Storage——如果答案是肯定的话，那么它会回应一个mount指令给vold，而后者对此的处理过程中会进一步调用到doMount函数——这个函数最关键的步骤之一是fork一个新进程，用于运行/system/bin/sdcard。

例如domount@EmulatedVolume.cpp中的如下代码段：

```
    if (!(mFusePid = fork())) {
        if (execl(kFusePath, kFusePath,
                "-u", "1023", // AID_MEDIA_RW
                "-g", "1023", // AID_MEDIA_RW
                "-m",
                "-w",
                mRawPath.c_str(),
                label.c_str(),
                NULL)) {
            PLOG(ERROR) << "Failed to exec";
        }

        LOG(ERROR) << "FUSE exiting";
        _exit(1);
    }
```

变量kFusePath指向的是“/system/bin/sdcard”，我们可以通过execl系统调用将其启动起来。Sdcard daemon对应的源代码目录是AOSP/system/core/sdcard。

Sdcard daemon属于Fuse Service。Fuse的全称是“Filesystem in Userspace”，即在用户态实现的一种File System。它的典型框架如图7-4所示。

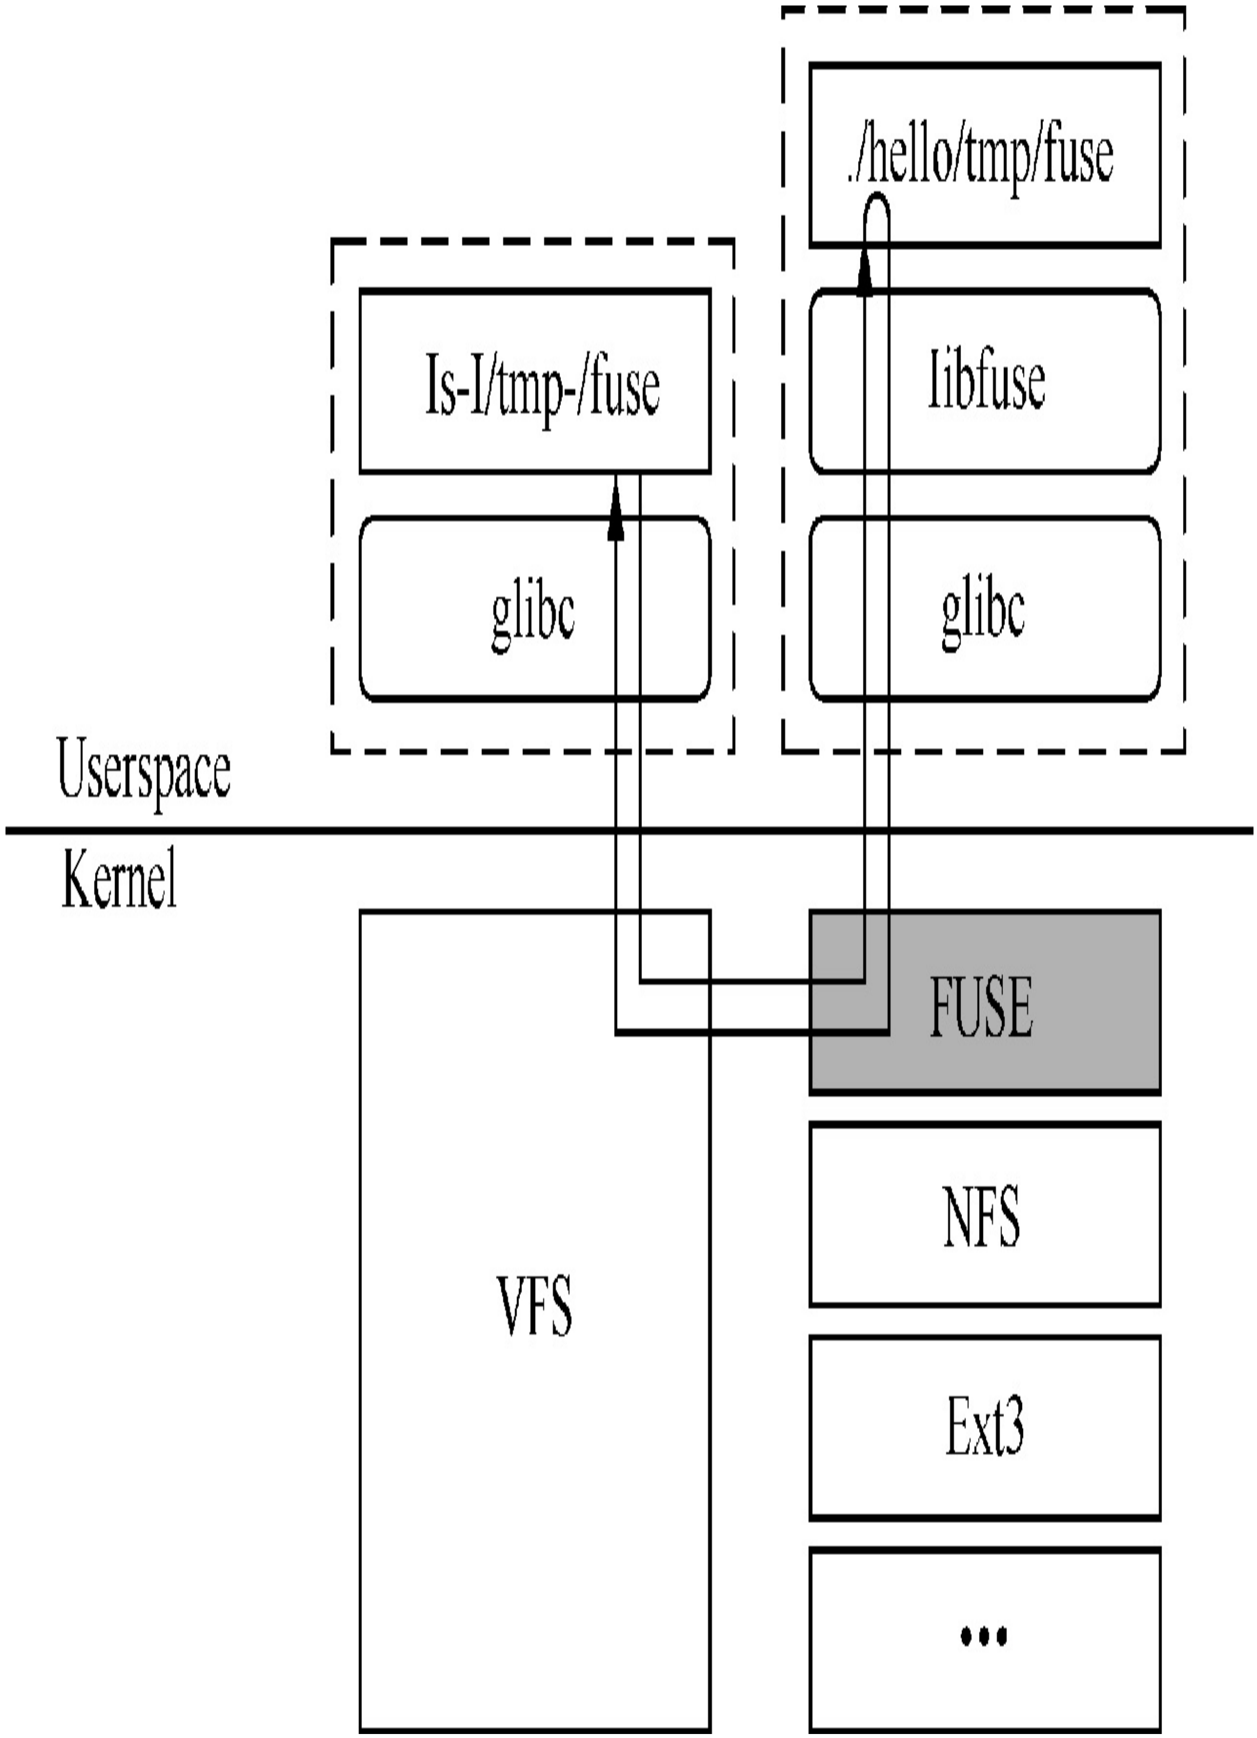
./hello/tmp/fuse
Is-I/tmp-/fuse
libfuse
glibc
glibc
Userspace
Kernel
FUSE
NFS
VFS
Ext3
...

▲图7-4　框架 {-:-}（引用自Wikipedia）

当使用者（左半部分）希望访问FUSE文件系统时，这一请求会经过Kernel的VFS首先传递给FUSE对应的驱动模块，然后再通知到用户层的fuse管控程序（例如这个场景中的sdcard）。后者处理请求完成后会将结果数据返回给最初的调用者，从而完成一次交互过程。可见与传统的文件系统相比，FUSE文件系统因为处理层次较多，所以在效率上注定会存在不足的地方。不过“瑕不掩瑜”，FUSE文件系统的灵活性依然为其获得了广泛的应用。

了解了FUSE文件系统后，我们再来看sdcard daemon是怎么做的。简单来说它会执行以下几个核心操作。

- 将/dev/fuse挂载到3个目标路径下

这几个目标路径分别是：/mnt/runtime/default/%s、/mnt/runtime/read/%s和/mnt/runtime/write/%s，其中“%s”代表的是Volume的label，在Emulated Storage这个场景下对应的是“emulated”。

- 创建3个线程

在代码中对应的是thread_default、thread_read和thread_write。这3个线程启动后都会进入for死循环，然后不停地从自己对应的fuse->fd（即打开/dev/fuse产生的文件描述符）中读取fuse模块发过来的消息命令，并根据命令的具体类型（例如FUSE_READ、FUSE_WRITE、FUSE_OPEN等）执行处理函数。

为什么我们需要将/dev/fuse挂载到3个路径下，并通过不同的线程来管理呢？这和Android 6.0中引入的Runtime Permission有关系。

不同于以往Install Time Permissions（应用程序所需的权限是在安装或者版本升级过程中赋予的）这种“一刀切”的管理方式，Runtime permission允许用户在程序运行到某些特别功能时再动态决定是否赋予程序相应的权限。这样带来的好处是用户可以更清楚地知道应用程序需要（或者已经授予了）哪些权限，以实现更为“透明”的管理。不过Runtime Permission只对那些系统认为危险的权限进行保护，

大家可以利用如下命令获取详细的权限列表：

```
adb shell pm list permissions -g -d
```

下面是某Android 6.0设备执行上述命令后的结果截图。

```
group:android.permission-group.LOCATION
  permission:android.permission.ACCESS_FINE_LOCATION
  permission:com.google.android.gms.permission.CAR_SPEED
  permission:android.permission.ACCESS_COARSE_LOCATION

group:android.permission-group.STORAGE
  permission:android.permission.READ_EXTERNAL_STORAGE
  permission:android.permission.WRITE_EXTERNAL_STORAGE
```

从图中可以看到读写外置存储设备的权限就在此列。

从开发者的角度来看，当应用程序运行到需要Runtime Permission的功能时（也有应用程序在启动时一口气申请所有Runtime Permission，从而导致很不好的用户体验，这种做法是不推荐的），手动调用相应的系统API进行权限申请，此时会弹出类似于下面的对话框供用户选择，如图7-5所示。

如果用户拒绝了应用程序的权限请求，并且勾选了“Never ask again…”，那么应用程序下次再申请同一权限时系统将直接拒绝。这种情况下应用程序的一种常见处理方法是自行弹出一个提示框，阐述申请此权限的重要性，以保证用户可以被充分说服，并手动去系统设置中进行授权操作。范例如图7-6所示。

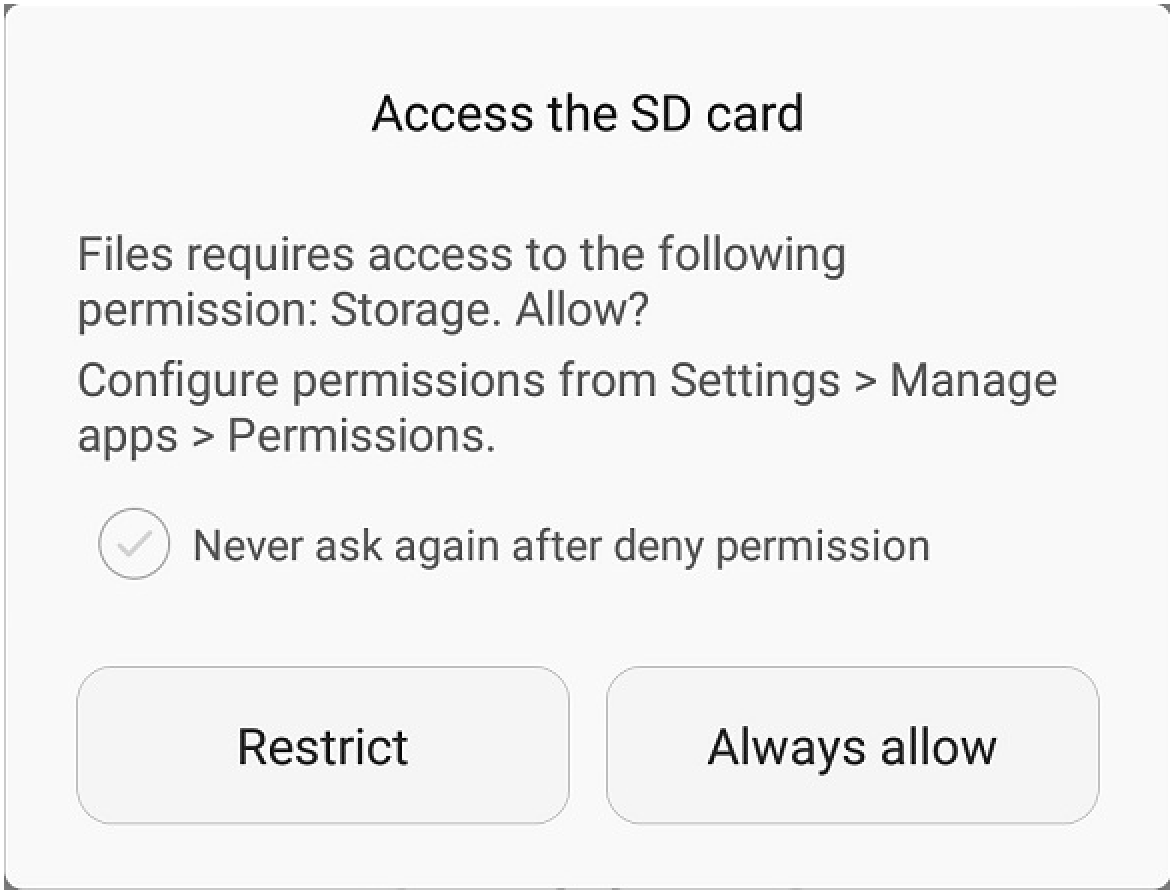
Access the SD card
Files requires access to the following permission: Storage. Allow?
Configure permissions from Settings > Manage apps > Permissions.
Never ask again after deny permission
Restrict
Always allow

▲图7-5　对话框

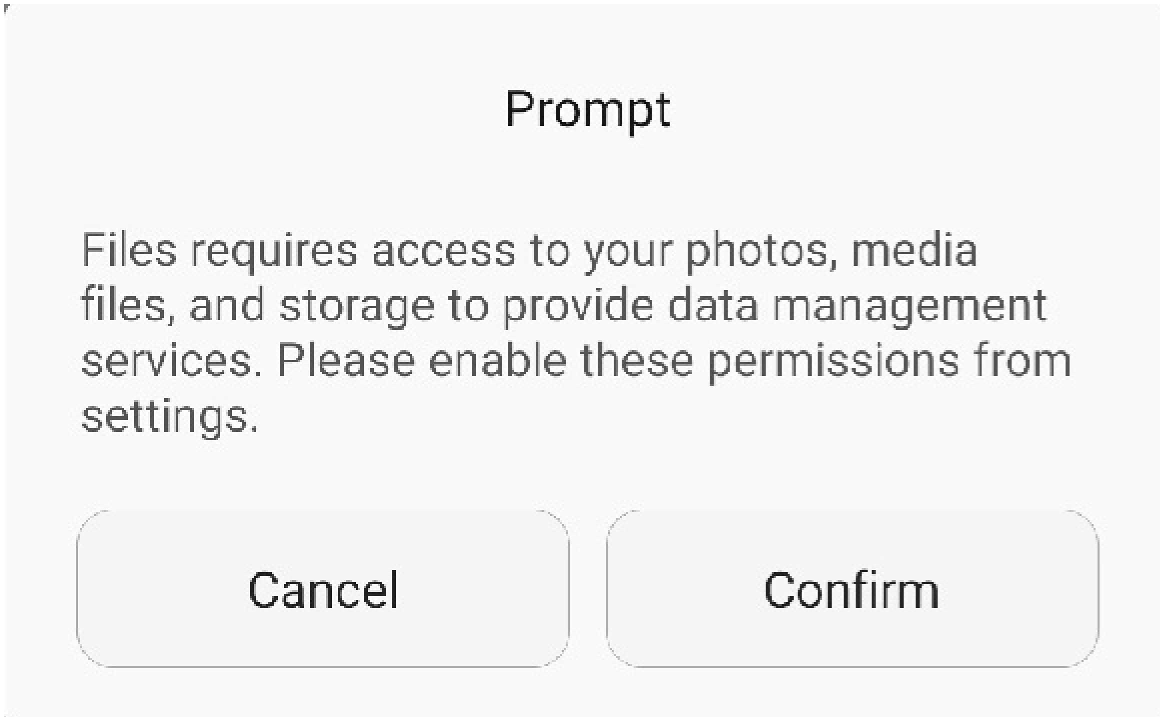

▲图7-6　进行授权操作

可见Runtime Permission权限管理方式的一种很重要的特性就是要求应用程序的权限可以在运行过程中进行动态调整，而且不能导致应用程序的重启。这其中就涉及Package Manager Service、Activity Manager Service、Zygote等多个系统服务，我们按照顺序逐一阐述。

首先需要关注的是应用程序启动时的初始化权限处理，此时AMS在startProcessLocked中会做如下处理：

```
/*frameworks/base/services/core/java/com/android/server/am/Activi
private final void startProcessLocked(ProcessRecord app, String h
     String hostingNameStr, String abiOverride, String entryPoint
try {
            checkTime(startTime, "startProcess: getting gids from
            final IPackageManager pm = AppGlobals.getPackageManag
            permGids = pm.getPackageGids(app.info.packageName, ap
            MountServiceInternal mountServiceInternal = LocalServ
            MountServiceInternal.class);
            mountExternal = mountServiceInternal.getExternalStora
                       app.info.packageName);
} catch (RemoteException e) {
throw e.rethrowAsRuntimeException();
}
```

```
…
Process.ProcessStartResult startResult = Process.start(ent
           app.processName, uid, uid, gids, debugFlags, mo
           app.info.targetSdkVersion, app.info.seinfo, req
           instructionSet, app.info.dataDir, entryPointArg
```

我们需要特别注意的是mountExternal这个变量的赋值过程，它将为后续Zygote中的bind mount提供参考。从上面的代码段不难看出，mountExternal是由MountService提供的，其代码实现如下所示：

```
public int getExternalStorageMountMode(int uid, String pa
    // No locking - CopyOnWriteArrayList
    int mountMode = Integer.MAX_VALUE;
    for (ExternalStorageMountPolicy policy : mPolicies) {
        final int policyMode = policy.getMountMode(uid, p
        if (policyMode == Zygote.MOUNT_EXTERNAL_NONE) {
            return Zygote.MOUNT_EXTERNAL_NONE;
        }
        mountMode = Math.min(mountMode, policyMode);
    }
    if (mountMode == Integer.MAX_VALUE) {
        return Zygote.MOUNT_EXTERNAL_NONE;
    }
    return mountMode;
}
```

这个函数的处理逻辑是：遍历所有的Policy规则，并从中挑选出数值最小的MountMode——按照由小而大的顺序排列，它们依次是：MOUNT_EXTERNAL_NONE、MOUNT_EXTERNAL_DEFAULT、MOUNT_EXTERNAL_READ和MOUNT_EXTERNAL_WRITE。应用程序的MountMode的具体取值主要由PMS的checkUidPermission来判断，而后者则会根据APP在AndroidManifest中申请WRITE_MEDIA_STORAGE、READ_EXTERNAL_STORAGE和WRITE_EXTERNAL_STORAGE等权限的情况来给出结论。

当Zygote孵化出一个应用程序进程后，会在MountEmulatedStorage中对Mount Mode做进一步处理，核心实现如下：

```
if (unshare(CLONE_NEWNS) == -1) {
    ALOGW("Failed to unshare(): %s", strerror(errno));
    return false;
}
String storageSource;
```

```
    if (mount_mode == MOUNT_EXTERNAL_DEFAULT) {
        storageSource = "/mnt/runtime/default";
    } else if (mount_mode == MOUNT_EXTERNAL_READ) {
        storageSource = "/mnt/runtime/read";
    } else if (mount_mode == MOUNT_EXTERNAL_WRITE) {
        storageSource = "/mnt/runtime/write";
    } else {
        // Sane default of no storage visible
        return true;
    }
    if (TEMP_FAILURE_RETRY(mount(storageSource.string(), "/storag
            NULL, MS_BIND | MS_REC | MS_SLAVE, NULL)) == -1) {…
}
```

我们不得不承认Android的很多新功能是和Linux Kernel的更新换代息息相关的，例如上述代码段中就用到了mount namespace、bind mount等多项内核技术。建议大家可以先自行查阅相关资料了解这些技术。

Android 6.0中引入了如下几个被称为“View”的mount point:

- /mnt/runtime/default

提供给没有特殊权限的应用程序，以及adbd等系统组件所在的root namespace。

- /mnt/runtime/read

提供给那些具有READ_EXTERNAL_STORAGE权限的应用程序。

- /mnt/runtime/write

提供给那些具有WRITE_EXTERNAL_STORAGE权限的应用程序。

透过不同的“View”所能“看到”的Mount Tree是不一样的，从而实现了程序在外部存储上的分权限管理。更为重要的是，采用这种实现方式在应对Runtime Permission变化时是不需要重启应用程序就可以生效的。具体来说，当程序取得Storage新的Runtime Permission以后，PMS会通过MountService向Vold的CommandListener发送一条名为“remount_uid”的命令，后者则进一步将消息传递给Vold的VolumeManager::remountUid函数——在这个函数中就可以对相应的进

程进行“视角”的重新调整，从而达到我们的预期效果。

其他Runtime Permission的实现原理也是类似的，大家可以自行分析了解。

7.3 多用户管理

Android的多用户管理功能并不算流行，但是它会影响到不少模块的内部实现，譬如存储管理、权限管理等（参考上一小节）。因而我们放在本章节做一个简单的介绍，以便读者在遇到类似场景时有一个清楚的认识。

多用户管理意味着我们可以在同一台设备中支持多个使用者。类似于Windows系统中的做法，Android中的用户也是分类型的，具体如下所示。

- Primary

这是设备的第一个同时也是首选的用户，类似于Windows中的Administrator。Primary User是不能被删除的，而且会一直处于运行状态。另外，它拥有一些特殊的权限和设置项。

- Secondary

这是被添加到设备中的除primary user外的其他用户。它可以被移除，并且不能影响设备中的其他用户。

- Guest

临时性的secondary user，系统中同时只能有一个Guest user。

用户类型也直接决定了它们的权限范围，例如只有primary user才拥有对phone call和texts的完全控制权。而secondary默认情况下只能接听电话，而无权拨打或者操作短信功能。当然，这也取决于Settings->Users中针对secondary user的授权情况。

用户安装的程序虽然都在/data/app目录下，但是它们的数据存储位置则有所差异。具体来说，/data/data目录下保存的是Primary User的数据，而其他用户的数据则被放置于/data/user/<uid>/中（/data/user/0和/data/data中的内容是一致的）。

不过从Android 5.0开始，多用户的特性默认情况下是被关闭的。

我们需要修改以下配置文件来打开：

```
/*frameworks/base/core/res/res/values/config.xml*/
    <!--  Maximum number of supported users -->
    <integer name="config_multiuserMaximumUsers">1</integer>
    <!-- Whether UI for multi user should be shown -->
    <bool name="config_enableMultiUserUI">false</bool>
```

设备商可以根据需要来修改上述两个配置项，只有这样才能开启设备的多用户功能。

第8章 管理Activity和组件运行状态的系统进程——ActivityManagerService（AMS）

ActivityManagerService（AMS）是Android提供的一个用于管理Activity（和其他组件）运行状态的系统进程，也是我们编写APK应用程序时使用得最频繁的一个系统服务。

本章内容编排如下：

- AMS功能概述

虽然开发者经常会使用到AMS提供的一些功能，但可能鲜有机会对它进行统一的整理与分析。因此我们先对AMS的功能进行整体概述，从而为后面分析其内部实现打下基础。

- ActivityStack

理解了AMS所需完成的功能后，我们会深入代码层来讲解它们的实现——其中最重要的两个核心就是ActivityStack和ActivityTask。

从名称就可以看出，ActivityStack是Activity的记录者与管理者，同时也为AMS管理系统运行情况提供了基础。

- ActivityTask

Task是Android应用程序中的一大利器，而且其中涉及的逻辑关系

相对复杂，因而我们专门用一个小节具体讲解。

8.1　AMS功能概述

和WMS一样，AMS也是寄存于systemServer中的。它会在系统启动时，创建一个线程来循环处理客户的请求。值得一提的是，AMS会向ServiceManager登记多种Binder Server 如“activity”“meminfo”“cpuinfo”等——不过只有第一个“activity”才是AMS的“主业”，并由Activity ManagerService实现；剩余服务的功能则是由其他类提供的。

先来看看AMS的启动过程。如下所示：

```
/*frameworks/base/services/java/com/android/server/SystemServer.j
public void run() {
     …
     Slog.i(TAG, "Activity Manager");
     context = ActivityManagerService.main(factoryTest); //启动AMS
     …
     ActivityManagerService.setSystemProcess(); //向Service Manage
     …
}
```

ActivityManagerService提供了一个静态的main函数，通过它可以轻松地启动AMS。然后还需要调用setSystemProcess来把这个重要系统服务注册到ServiceManager。由此可见它和WMS一样，都是“实名”的Binder Server：

```
/*frameworks/base/services/java/com/android/server/am/ActivityMan
    public static final Context main(int factoryTest) {
        AThread thr = new AThread(); //创建AMS线程
        thr.start(); //启动AMS线程
        synchronized (thr) {
           while (thr.mService == null) {/*注意，这段代码是运行在Syst
              所以通过mService是否为空来判断AMS成功启动与否：如果是的话就
              继续执行，否则就一直等待。Android在处理“系统级进程”出错时的
              了，任何补救都是无力回天的”，所以它的异常处理部分经常是空的*/
                try {
                    thr.wait();
                } catch (InterruptedException e) {
                }
            }
        }
        …
```

```
        m.mMainStack = new ActivityStack(m, context, true); /*创建
                                                    这是AMS的核心，很多工作都是
        …
        return context;
    }
```

我们在线程章节讨论过wait的用法，这里就是一个典型应用。对于SystemServer所在线程来说，它需要等到AThread（即上述的变量thr）成功启动后才能继续往下执行。所以当thr.start()后，就通过thr.wait()进入等待。那么，什么时候唤醒呢？答案就在AThread内部：

```
static class AThread extends Thread {…
    public void run() {…
          synchronized (this) {
                mService = m;
                mLooper = Looper.myLooper();
                notifyAll();
            }
```

上面的notifyAll会唤醒所有在thr这个object所在等待队列上的目标，自然也就包括了SystemServer所属线程。这么做的原因是SystemServer的后续运行将依赖于AMS，所以如果在AMS还未就绪的情况下就贸然返回，很可能会造成系统宕机。

将AMS注册到ServiceManager很简单，唯一要注意的是它不只注册了自己一个Server，而是一系列与进程管理相关的服务。如下所示：

```
    public static void setSystemProcess() {
        try {
            ActivityManagerService m = mSelf;
            ServiceManager.addService("activity", m, true);//AMS的
            ServiceManager.addService("meminfo", new MemBinder(m)
            …//其他服务省略
    }
```

要了解AMS提供的所有功能，最好的方法就是查看IActivityManager.java。AMS所做的工作就是围绕这份接口声明展开的——不过因为文件行数比较多，此处不一行行列出，而是直接对它进行分类描述。

1. 组件状态管理

这里的组件不仅仅指Activity，而是所有四大组件。状态管理包括组件的开启、关闭等一系列操作，如startActivity、startActivityAndWait、activityPaused、startService、stopService、remove ContentProvider等。

2．组件状态查询

这类函数用于查询组件当前的运行情况，如getCallingActivity、getServices等。

3．Task相关

Task相关的函数包括removeSubTask、removeTask、moveTaskBackwards、moveTaskToFront等。本章最后一个小节将会重点介绍Task。

4．其他

除了上述类型的函数外，AMS还提供了不少辅助功能，如系统运行时信息的查询（getMemory Info，setDebugApp等）。

接下来的两个小节，我们主要分析AMS中与“组件和Task部分”相关功能的实现原理。

8.2　管理当前系统中Activity状态——Activity Stack

我们在查看AMS代码时，会发现很多地方用到了一个名为mMainStack的变量。它是ActivityStack类型的对象，并且在AMS启动时就创建出来了：

```
/*frameworks/base/services/java/com/android/server/am/ActivityMan
public static final Context main(int factoryTest) {/*main()函数是启
     …
     ActivityManagerService m = thr.mService;
     …
     m.mMainStack = new ActivityStack(m, context, true, thr.mLoop
     …
}
```

从名称上看，ActivityStack是管理当前系统中所有Activity状态的一个数据结构。那么，是不是这样的呢？我们来看看这个类里面有哪些重要的成员元素和接口。

以下内容是从ActivityStack.java中提取出来的。

1．ActivityState

描述了一个Activity所可能经历的所有状态。其定义如下：

```
enum ActivityState {
       INITIALIZING, //正在初始化
       RESUMED,      //恢复
       PAUSING,      //正在暂停
       PAUSED,       //已经暂停
       STOPPING,     //正在停止
       STOPPED,      //已经停止
       FINISHING,    //正在完成
       DESTROYING,   //正在销毁
       DESTROYED     //已经销毁
    }
```

结合Activity状态改变时其自身所能收到的回调函数，我们来描述下它的状态迁移图。读者可以将图8-1和前面列出的各Activity状态做一个对照。

2．ArrayList

除了状态管理外，ActivityStack中还有一系列不同功能的ArrayList成员变量。它们的共同点在于列表元素都是ActivityRecord——这个类负责记录每个Activity的运行时信息。因而也可以看出，ActivityStack确实是AMS中管理Activity的“大仓库”。

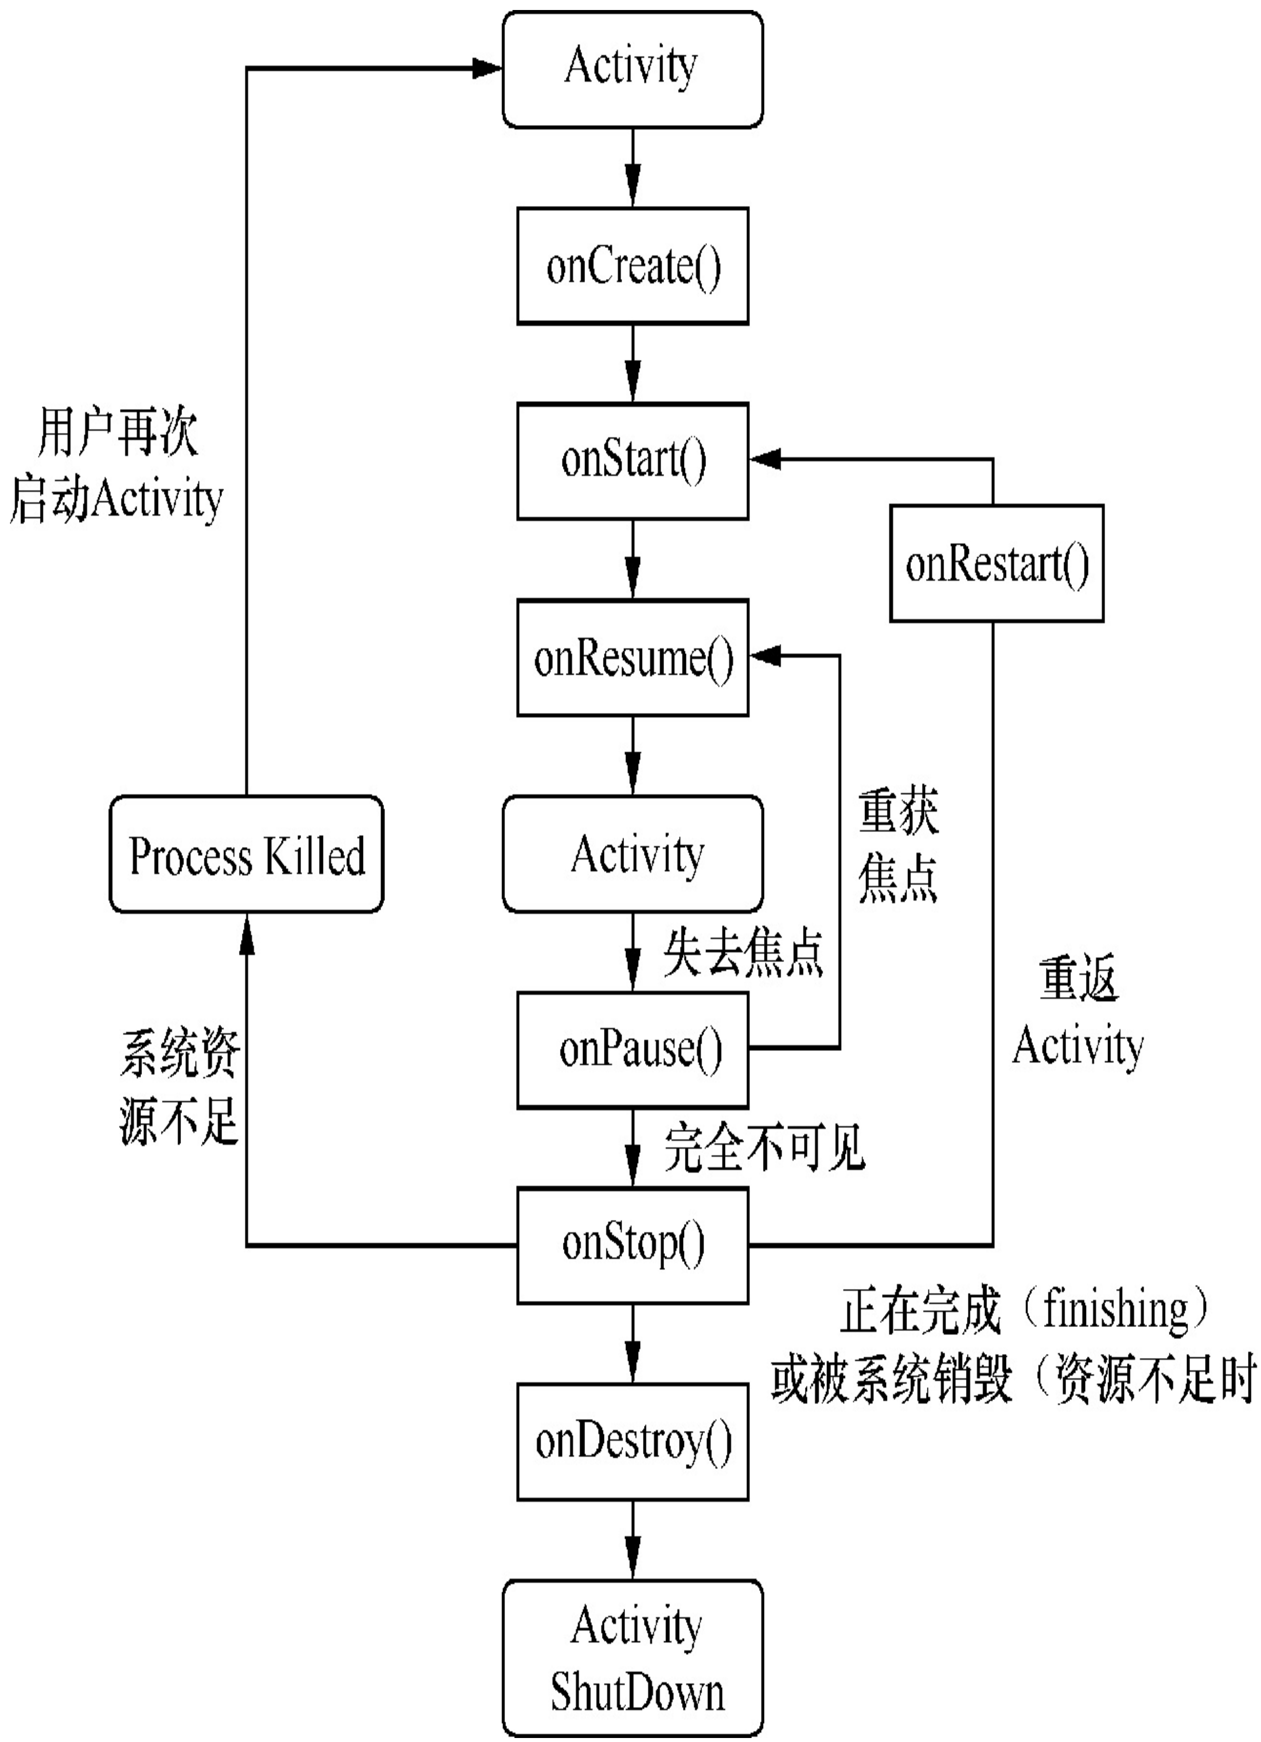

Activity
onCreate()
onStart()
onRestart()
onResume()
Activity
Process Killed
用户再次
启动Activity
重获
焦点
失去焦点
onPause()
重返
Activity
系统资
源不足
完全不可见
onStop()
正在完成（finishing）
或被系统销毁（资源不足时
onDestroy()
Activity
ShutDown

▲图8-1　Activity状态迁移图

表8-1列出了其中几个重要的ArrayList。

表8-1　ActivityStack管理的各ArrayList（部分）

ArrayList	Description
mHistory	所有Activity的信息在这里都有记录，直到它被destroyed
mLRUActivities	正在运行的Activity的列表集合，以最近的使用情况来排序，即队头元素是最近使用最少的元素
mStoppingActivities	列表中的Activity已经可以被Stop，但是还得等待下一个Activity处于就绪状态
mGoingToSleepActivities	列表中的Activity正在进入睡眠状态
mNoAnimActivities	列表中的Activity不考虑状态间迁移动画
mFinishingActivities	列表中的Activity已经可以被finished，但还需要等待上一个Activity就绪

3．记录特殊状态下的Activity

除了上面的ArrayList用来描述各种状态下的Activity集合外，ActivityStack还通过以下多个变量来专门记录一些特殊状态下的Activity实例，具体如表8-2所示。

表8-2　特殊状态下的Activity

ActivityRecord	Description
mPausingActivity	当前正在被暂停（pausing）的Activity
mLastPausedActivity	上一个被暂停的Activity
mResumedActivity	当前被恢复（resumed）的Activity，可以为null
mLastStartedActivity	最近一次被启动的Activity

以上所述的3类变量构成了ActivityStack的主框架。如果用一句话来简单概述AMS的功能，就是：

“AMS是通过ActivityStack（和其他数据结构）来记录、管理系统中的Activity（和其他组件）状态，并提供查询功能的一个系统服务。”这句话包含了以下几个重点。

1．AMS的主要工作就是管理、记录、查询

打个比方，AMS就像户籍登记处。所有新加入或者注销的家庭都需要到这里办理业务；而且它还提供对外的查询功能——这点类似于公安局开具的“户籍证明”，用于表明办证者当前的户口状态。

2．AMS是系统进程的一部分（确切地说它运行于一个独立的线程中）

从内核的角度来说，AMS其实也是普通进程中的一部分，只不过它提供的是全局性的系统服务。接着上面打的比方，户籍登记处和家庭一样，也是在一个“房子”（进程）里运行的。它有一套严格的办事规程（线程），来处理户主的各种请求（登记、注销、查询等）。值得一提的是，AMS的任务只是负责保管Activity（及其他组件）的状态信息，而像Activity中描述的UI界面如何在物理屏幕上显示等工作则是由WindowManagerService和SurfaceFlinger来完成的（后续章节有详细讲解）。

8.3 startActivity流程

前两个小节理清了AMS所能提供的功能以及内部的一些重要变量。那么，AMS具体是如何开展工作的呢？

如果单纯从理论的角度来分析，大家很可能会有“云里雾里”的感觉。所以本小节将以一个范例为线索，把AMS中的主体框架和工作流程贯穿起来——这个例子就是startActivity()函数的执行过程（在讲解过程中我们会省略Binder通信等中间细节，因为这部分内容在前面章节已有详细阐述）。

相信大家对startActivity(Intent)的功能不会陌生。它用于启动一个目标Activity——具体是哪个Activity则是AMS通过对系统中安装的所有程序包进行“Intent匹配”得到的，并不局限于调用者本身所在的package范围。换句话说，startActivity()最终很可能启动的是其他进程中的组件。当系统匹配到某个目标Activity后分为两种情况。

- 如果通过Intent匹配到的目标对象，其所属程序包中已经有其他元素在运行（意味着该程序进程已启动），那么AMS就会通知这个进程来加载运行我们指定的目标Activity。
- 如果当前Activity所属程序没有进程在运行，AMS就会先启动它的一个实例，然后让其运行目标Activity。

先大致讲解一下startActivity()所经历的函数调用流程，从调用方（Activity1）开始：Activity1➞startActivity@ContextImpl.java➞execStartActivity@InstrumentatService.java。

因而经过层层中转后，调用者发起的startActivity最终还是在AMS中实现的。接下来的问题就转化为：AMS内部对startActivity是如何处理的？

“理想很丰满，现实很骨感”，看似简单的一个功能，实际上AMS要做的工作还是很多的——首先来辨别下AMS中5个“长相”类似的startActivity函数，以防后期混淆。统一列出如下：

- startActivity@ActivityManagerService.java
- startActivityAsUser@ ActivityManagerService.java
- startActivityMayWait@ActivityStack.java
- startActivityLocked@ActivityStack.java
- startActivityUncheckedLocked@ActivityStack.java

这5个函数存在先后调用的关系。源代码如下：

```
/*frameworks/base/services/java/com/android/server/am/ActivityMan
    public final int startActivity(IApplicationThread caller, Str
           Intent intent, String resolvedType, IBinder resultTo,
           String resultWho, int requestCode, int startFlags,
           String profileFile, ParcelFileDescriptor profileFd, Bu
        return startActivityAsUser(caller, callingPackage, intent
                       result To, resultWho, requestCode, star
                        profileFile, profileFd, options,UserHa
    }
```

可以看到，startActivityAsUser与startActivity只多了最后一个参数userId，它表示调用者的用户ID值，因而可以通过Binder机制的getCallingUid获得：

```
    public final int startActivityAsUser(IApplicationThread calle
          Intent intent, String resolvedType, IBinder resultTo,
          String resultWho, int requestCode, int startFlags, Stri
          ParcelFileDescriptor profileFd, Bundle options, int use
      enforceNotIsolatedCaller("startActivity");
      userId = handleIncomingUser(Binder.getCallingPid(), Binder.
            false, true, "startActivity", null);
      return mMainStack.startActivityMayWait(caller,-1,callingPac
            resultTo, resultWho, requestCode, startFlags, profile
            null, null, options, userId);/*这个函数是ActivityStack
    }
```

函数startActivityAsUser的一大重点就是做权限检查，包括：

- enforceNotIsolatedCaller

检查调用者是否属于被隔离的对象。

- handleIncomingUser

调用者是否有权力执行这一操作。

由此也可以看出，5个“startActivityXX”其实是5个执行步骤，而且一旦其中一步出现错误就会中止整个流程。

接着往下分析startActivityMayWait这个函数。因为代码很长，我们直接把其中的核心工作提取出来，如图8-2所示。

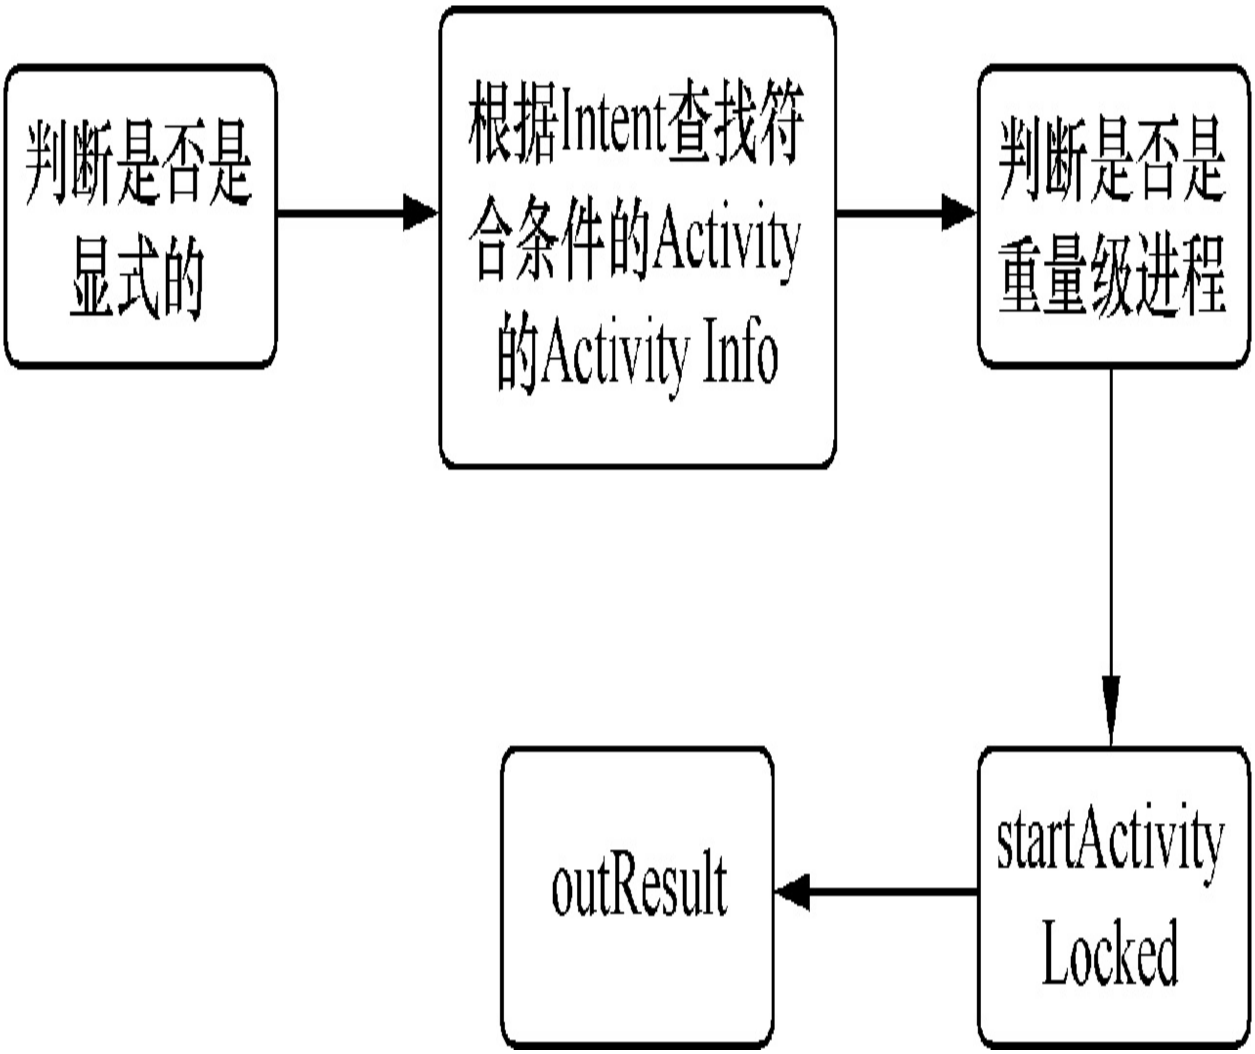

▲图8-2 startActivityMayWait

根据图8-2中的描述，在startActivityMayWait中：

- 然是要启动某个符合Intent要求的Activity，那么首先就应确定这个目标Activity：如果是显式的Intent，问题很好解决，因为Intent信息

中已经带有目标Activity的相关信息；否则就调用resolveActivity()进行查找——具体过程可以参见本书应用篇中Intent匹配章节的描述。

- 判断目标Activity所属进程是不是重量级（heavy-weight）的。如果当前系统中已经存在的重量级进程（mService.mHeavyWeightProcess）不是即将要启动的这个，那么就要给Intent重新赋值。
- 调用startActivityLocked来进一步执行启动工作。
- 如果outResult不为空，还需要将函数的结果写入这个变量中。因为前面startActivity传入时此参数为null，所以这里可以直接略过。

这个函数的名称表明它有可能会“wait”——具体就表现在对outResult的处理上。有兴趣的读者可以自行分析，具体如图8-3所示。

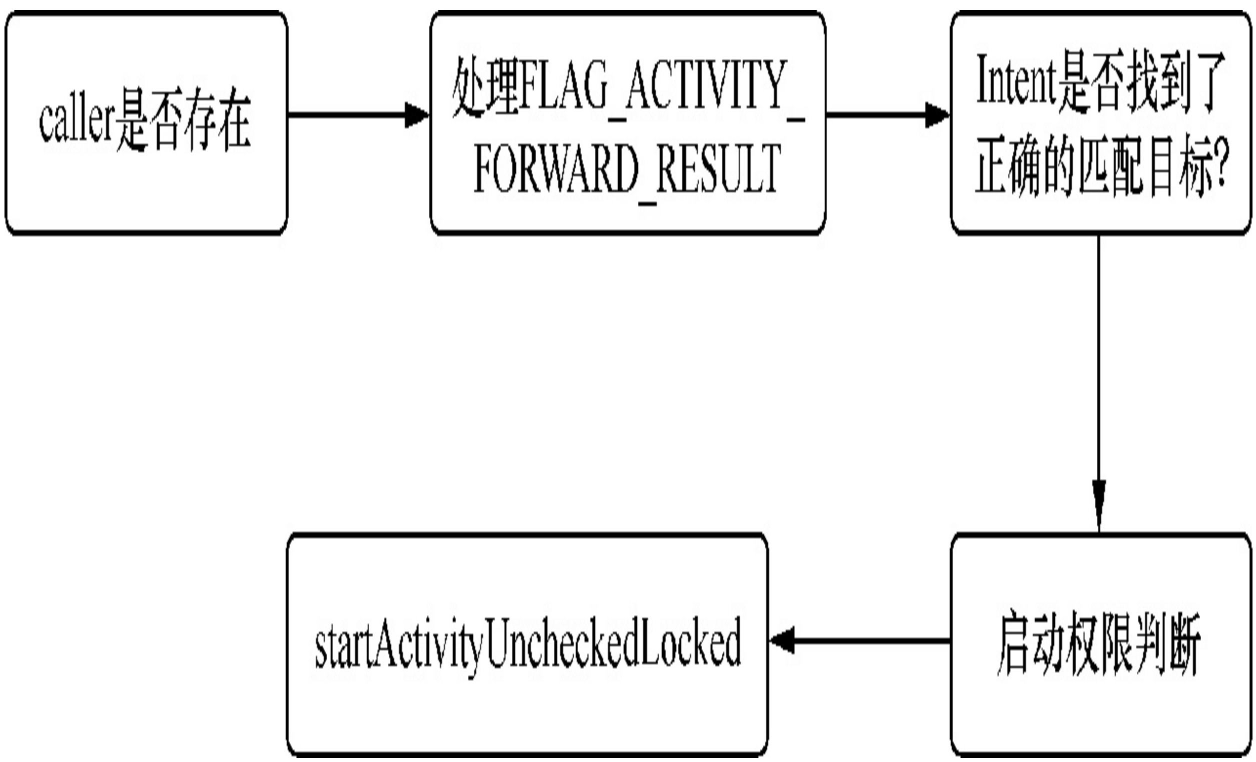

▲图8-3　startActivityLocked(1)执行流程

紧接着被调用的函数是startActivityLocked。需要特别注意的是，ActivityStack中存在两个同名的startActivityLocked函数，但参数不同。我们把参数较多的那个称为startActivityLocked（1），另一个则是startActivityLocked（2）。Android源码中的很多函数后面都

有Locked标志，用于提醒我们必须保证这些函数的线程安全——因为它们涉及不可重入资源的处理。图中所示的是startActivityLocked（1）函数的处理流程。主要工作是：

Step1@startActivityLocked（1），确保调用者本身的进程是存在的，否则就直接返回START_PERMISSION_DENIED错误。这种情况是有可能发生的，如调用者被系统杀死，或者异常退出等。

Step2@startActivityLocked(1)，处理FLAG_ACTIVITY_FORWARD_RESULT

这个标志具有跨越式传递的作用。比如Activity1正常启动了Activity2，而当Activity2启动Activity3时使用了这个标志，那么当Activity3调用setResult时，result并不会像一般情况中那样传递给Activity2，而是传递给最初的Activity1。

为了达到这一目的，就需要将新启动的Activity3的caller改为Activity1。具体如下所示：

```
if ((launchFlags&Intent.FLAG_ACTIVITY_FORWARD_RESULT)
        != 0&& sourceRecord != null) {
    if (requestCode >= 0) {
        ActivityOptions.abort(options);
        return ActivityManager.START_FORWARD_AND_REQUEST_
    }
    resultRecord = sourceRecord.resultTo;
    resultWho = sourceRecord.resultWho;
    requestCode = sourceRecord.requestCode;
    sourceRecord.resultTo = null;
    if (resultRecord != null) {
        resultRecord.removeResultsLocked(sourceRecord, re
    }
}
```

因为在这个标志下，Activity2已经把接收result的目标对象设置为Activity1，因而它自身不能再通过startActivityForResult来启动Activity3了，否则就会报START_FORWARD_AND_REQUEST_CONFLICT的错误。

Step3@startActivityLocked（1），如果此时还没有找到合适的目标Activity来处理Intent，或者这个目标的ActivityInfo为空，都说明这个Intent没有办法继续处理了，因此程序会直接报错返回。

Step4@startActivityLocked（1），上面的判断通过后，还需要查验调用者是否有权限来启动指定的Activity。具体如下所示：

```
final int startAnyPerm = mService.checkPermission(START_ANY_A
                                                          callingPid,
final int componentPerm = mService.checkComponentPermission(a
        callingPid, callingUid, aInfo.applicationInfo.uid, aI
```

上述这两个权限检查必须全部通过，否则会抛出SecurityException。

Step5@startActivityLocked（1），生成一个ActivityRecord变量r，记录当前的各项判断结果，然后进一步调用startActivityUncheckedLocked——这个函数里将涉及一系列启动模式和Intent标志的处理，建议读者穿插阅读ActivityTask小节中对这些标志的说明。

接下来我们再详细讲解startActivityUncheckedLocked这个函数。

Step1@startActivityUncheckedLocked，前期准备

首先得到Intent中的启动标志：

```
int launchFlags = intent.getFlags();
```

然后处理FLAG_ACTIVITY_NO_USER_ACTION。这个标志表示并不是用户“主观意愿”启动的Activity，而是如来电、闹钟事件等触发的Activity启动。

如果调用者指示先不要resume（doResume为空），那么我们将delayedResume设置为true。如果使用了FLAG_ACTIVITY_PREVIOUS_IS_TOP，则notTop为r本身，否则为空。

Step2@startActivityUncheckedLocked。START_FLAG_ONLY_IF_NEEDED

只在需要的情况下才启动目标，即如果被启动的对象和调用者是同一个，那么就没有必要重复操作。

Step3@startActivityUncheckedLocked。判断是否要启动新的Task

变量launchFlags是用于记录Activity的启动方式的。如果sourceRecord为空，表明我们应该启动一个新的task来容纳目标Activity，因而需要设置FLAG_ACTIVITY_NEW_TASK；否则如果sourceRecord的launchMode为LAUNCH_SINGLE_INSTANCE，或者目标ActivityRecord的launchMode为LAUNCH_SINGLE_INSTANCE和LAUNCH_SINGLE_TASK中的任何一个（launchMode是在AndroidManifest中设置的），也需要在新的Task中启动。

Step4@startActivityUncheckedLocked。在启动新Task的情况下无法返回结果值

如果上一步骤判断的结果是需要启动一个新的Task，那么目标Activity就和原先的调用者不在一个Task中了。由于startActivity的结果是没有办法跨越Task传递的，这时我们返回一个RESULT_CANCELED。

```
sendActivityResultLocked(-1, r.resultTo, r.resultWho, r.requestCo
                          Activity.RESULT_CANCELED, null);
```

Step5@startActivityUncheckedLocked。对于新Task的细化处理

```
     ActivityRecord taskTop = r.launchMode != ActivityInfo.LAUNCH
                        ? findTaskLocked(intent, r.info)
                        : findActivityLocked(intent, r.info);
```

如果不是LAUNCH_SINGLE_INSTANCE，那么我们调用findTaskLocked来找到符合要求的Task——此Task的最顶端就是我们要找的目标Activity；如果设置了标志LAUNCH_SINGLE_INSTANCE，说明这个Activity所在的Task只能容纳目标Activity一个实例。这两个函数，即findTaskLocked和findActivityLocked都有可能返回空。

如果用户设置了FLAG_ACTIVITY_RESET_TASK_IF_NEEDED，那么执行resetTaskIfNeeded Locked来清理Task。如果START_FLAG_ONLY_IF_NEEDED不为空，那么有两种可能：要么resume顶部的Activity（doResume不为空）；要么abort。

如果标志FLAG_ACTIVITY_NEW_TASK和FLAG_ACTIVITY_CLEAR_TASK同时存在，那么我们清理整个Task（performClearTaskLocked）；否则如果FLAG_ACTIVITY_CLEAR_TOP或者launchMode为singleTask（或

singleInstance），那么就清理目标Activity以上的那些元素；否则如果Task中最顶层Activity就是目标对象，那么我们把整个Task提到前台；否则如果设置了标志FLAG_ACTIVITY_RESET_TASK_IF_NEEDED，那么我们将目标对象加入Task顶端。

假如当前Task最顶端的Activity与我们的目标对象是同一个，那么我们需要确认这个目标是否只能启动一次。

Step6@startActivityUncheckedLocked。接下来的代码是基于newTask为false的情况，不过也有例外。比如设置了FLAG_ACTIVITY_NEW_TASK，但是经过前面的判断后addingToTask为false，此时newTask还是为真。

Step7@startActivityUncheckedLocked。最后调用startActivityLocked(2)来真正地执行启动操作。这个函数不仅是AMS启动Activity的关键，同时也是Activity后续能否在WMS中得到正常处理的关键。

函数startActivityLocked(2)是启动Activity的最后一站，主要包含以下几方面的工作。

Step1@startActivityLocked(2)。首先，如果目标Activity不是在新task中启动的，即newTask变量为false，那么程序要找出目标Activity位于哪个老task中（这可以通过遍历整个mHistory列表来实现）。找到后，如果这个task当前对用户还不是可见的，那么只需要将它加入mHistory，并在WMS中做好注册，但不启动它。

Step2@startActivityLocked(2)。将这个Activity放在stack的最顶层，这样才能与用户交互。添加的语句如下：

```
mHistory.add(addPos, r);
r.putInHistory();
r.frontOfTask = newTask;
```

上面代码的第一句在mHistory中添加r(ActivityRecord)对象，第二句则更新r内部变量并增加它所在task的Activity成员计数，最后一句表明这个Activity是否为此task的root元素——如果是新task的话，那么答案就是肯定的。

Step3@startActivityLocked(2)。接下来，如果不是AMS中的第一个Activity（mHistory中个数>0），则执行切换动画（不过这也要取决于FLAG_ACTIVITY_NO_ANIMATION标志）。执行的动画类型分为WindowManagerPolicy.TRANSIT_TASK_OPEN（如果是启动新的task）及Window ManagerPolicy.TRANSIT_ACTIVITY_OPEN（不启动新的task）两种。

Step4@startActivityLocked(2)。一个Activity的UI界面为了在终端屏幕上显示出来，很重要的一点就是它在WMS中必须“有档可查”。这个“档”就是appToken，它是在startActivity中添加的。即：

```
mService.mWindowManager.addAppToken(
       addPos, r.appToken, r.task.taskId, r.info.screenOrientatio
```

后续在WMS章节中还会看到关于这个appToken的更多讲解。

Step5@startActivityLocked(2)。在ActivityStack小节，我们说过Activity是有affinity的——言下之意，就是它们“更亲近”与某些affinity相符的task。因而如果启动了一个新task，就需要检查是否存在“同兴趣”的其他Activity。另外，如果用户使用了FLAG_ACTIVITY_RESET_TASK_IF_NEEDED，就满足“NEEDED”条件了，因而需要调用resetTaskIfNeededLocked。

Step6@startActivityLocked(2)。调用resumeTopActivityLocked

至此，startActivity函数的一系列处理流程就分析完了——只不过Activity的启动过程还没有结束。一方面，AMS会继续调用resumeTopActivityLocked来恢复最上层的Activity，并pause之前的Activity；另一方面，在Activity切换的过程中还要首先展示切换动画，然后两个新旧Activity还会向WMS分别申请和释放Surface，最终将它们显示/不显示在屏幕上。这些内容会在WMS章节中再详细分析。

这里先看看resumeTopActivityLocked函数的处理。

Step1@resumeTopActivityLocked。调用topRunningActivityLocked，用于从mHistory中取出ActivityStack中最上面有效的ActivityRecord。代码如下：

```
  int i = mHistory.size()-1;//所有Activity的数量
```

```
while (i >= 0) {
    ActivityRecord r = mHistory.get(i);
    if (!r.finishing && r != notTop && okToShow(r)) {
        return r;
    }
    i--;
}
return null;
```

其中notTop是函数的入参，这里是null。函数按照顺序从mHistory中逐个取出ActivityRecord进行判断，直到符合下列要求的元素出现：状态不是finishing，不等于notTop（即null），且可以被显示出来（一种特殊的情况是当系统锁屏时，要求这个Activity必须带有FLAG_SHOW_ON_LOCK_SCREEN标志）。由topRunningActivityLocked返回的ActivityRecord结果将赋值给resume TopActivityLocked函数中的next变量——要特别注意的是，它有可能为空。比如系统第一次开机时，此时mHistory的size为0。

Step2@resumeTopActivityLocked。假如next为空，那么我们就要启动Launcher主界面。换句话说，无论何时Android系统都会有正在运行的Activity，默认就是Launcher。

Step3@resumeTopActivityLocked。判断当前正在运行的Activity是否就是目标对象（mResumedActivity == next && next.state == ActivityState.RESUMED），如果答案是肯定的就没有必要重复启动了。

Step4@resumeTopActivityLocked。假如目标Activity正在stopping，那么就要终止它的这一操作，即从mStoppingActivities，mGoingToSleepActivities，mWaitingVisibleActivities中将它移除，sleeping标志置false。

Step5@resumeTopActivityLocked。执行到这里，说明准备工作已经就绪。接下来程序分为几个方向。如果mPausingActivity不为空，证明当前正在pause前一个Activity，我们要等待操作结束，所以函数中止，直接返回false；否则如果mResumedActivity不为空，说明前一个Activity还在运行，那么就要先执行pause操作，流程如图8-4所示。

Step6@resumeTopActivityLocked。如果即将启动的Activity不是可见的（nowVisible为false），将其添加到

mWaitingVisibleActivities中；否则我们需要隐藏前一个Activity，即调用WMS中的setAppVisibility（prev.appToken，false）。

Step7@resumeTopActivityLocked。在启动新Activity之前，需要通知WMS前一个显示的Activity即将被隐藏（setAppWillBeHidden）。

Step8@resumeTopActivityLocked。接下来可以正式启动目标Activity了。分为两种情况：要么目标Activity所属程序已有进程实例在运行；要么Activity的承载进程还没有启动。

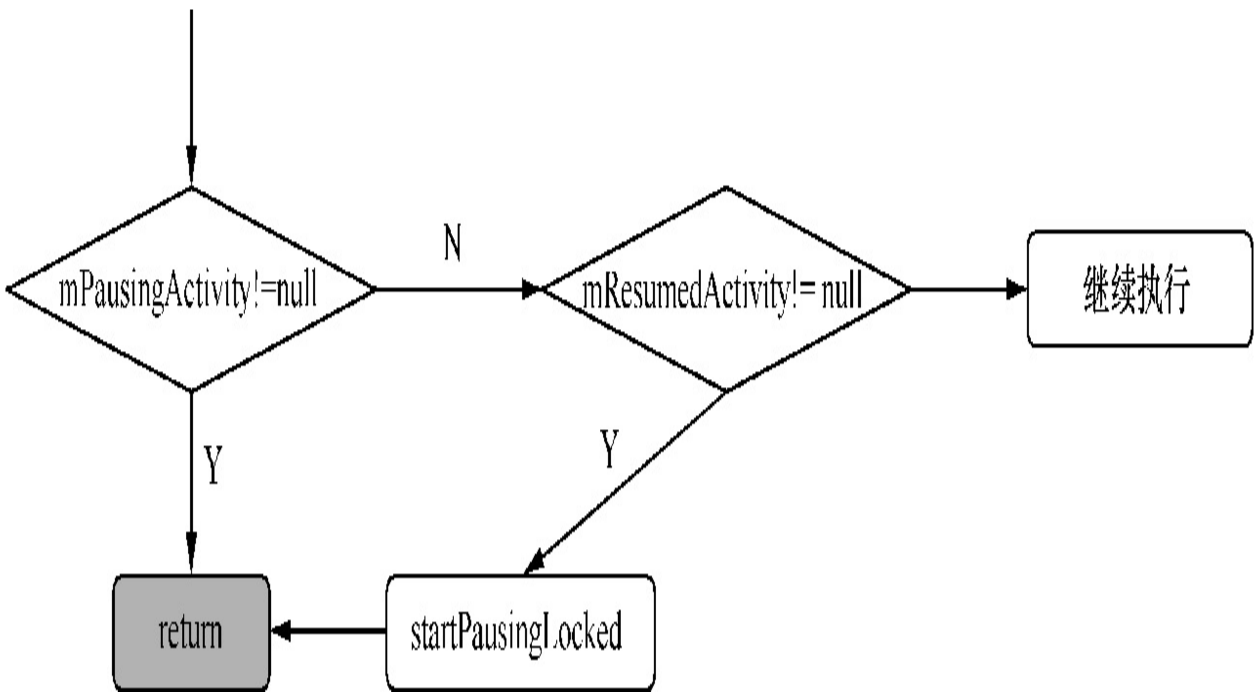

▲图8-4　流程图

假如是第一种情况，也就是：

```
next.app != null && next.app.thread != null
```

那么我们可以通知WMS这个Activity已经具备了显示的条件。即：

```
mService.mWindowManager.setAppVisibility(next.appToken, true);
```

然后更新一系列全局变量，如mResumedActivity；并刷新与此操作相关的统计数据，如updateCpuStats，addRecentTaskLocked等。如果有任何正在等待启动结果的对象，我们也要一一通知，然后通过：

```
next.app.thread.scheduleResumeActivity(next.appToken, mService.is
```

告知目标线程要resume指定的Activity。

如果是第二种情况，也就是目标Activity所属程序并没有进程在运行的话，那么处理过程就要复杂一些——首先要调用startSpecificActivityLocked来启动能承载目标Activity的进程。和startActivity一样，这个函数会不断调用多个“长相”类似的函数实现，即startSpecificActivity Locked→startProcessLocked(1)→startProcessLocked(2)，最终调用Zygote来启动一个新进程。具体如下所示：

```
Process.ProcessStartResult startResult =
           Process.start("<strong>android.app.ActivityThread</str
                        debugFlags,app.info.targetSdkVersion, nul
```

由上面的代码段也可以看出，当一个应用程序进程启动时，实际上加载了ActivityThread这一主线程。那么，新启动的进程在什么时候会真正运行目标Activity呢？

细心的读者一定已经想到了，进程启动后还需要通知AMS，后者才能继续执行之前未完成的startActivity。AMS预留了一段时间来等待这一回调，在不同的设备上标准有所差异：要么是10秒，要么是300秒。假如被启动的进程没有在指定的时间内完成attachApplication回调，那么AMS就认为发生了异常。如果新启动的进程在规定时间内正常调用了attachApplication，那么AMS就会判断当前是不是有Activity在等待这个进程的启动。如果是的话就调用realStartActivityLocked（看到源码作者取函数名称时的用心良苦了吧？这时才是真正启动Activity的地方。）继续之前的任务。接着就是应用程序开发人员所熟悉的一系列Activity生命周期的开始：onCreate→onStart→onResume等，并且在WMS与SurfaceFlinger的配合下，目标Activity描述的UI界面会呈现到物理屏幕上——至此，整个startActivity的流程才算真正完成。

我们用以下函数调用流程图来小结一下本节的内容。AMS中startActivity的过程如图8-5所示。

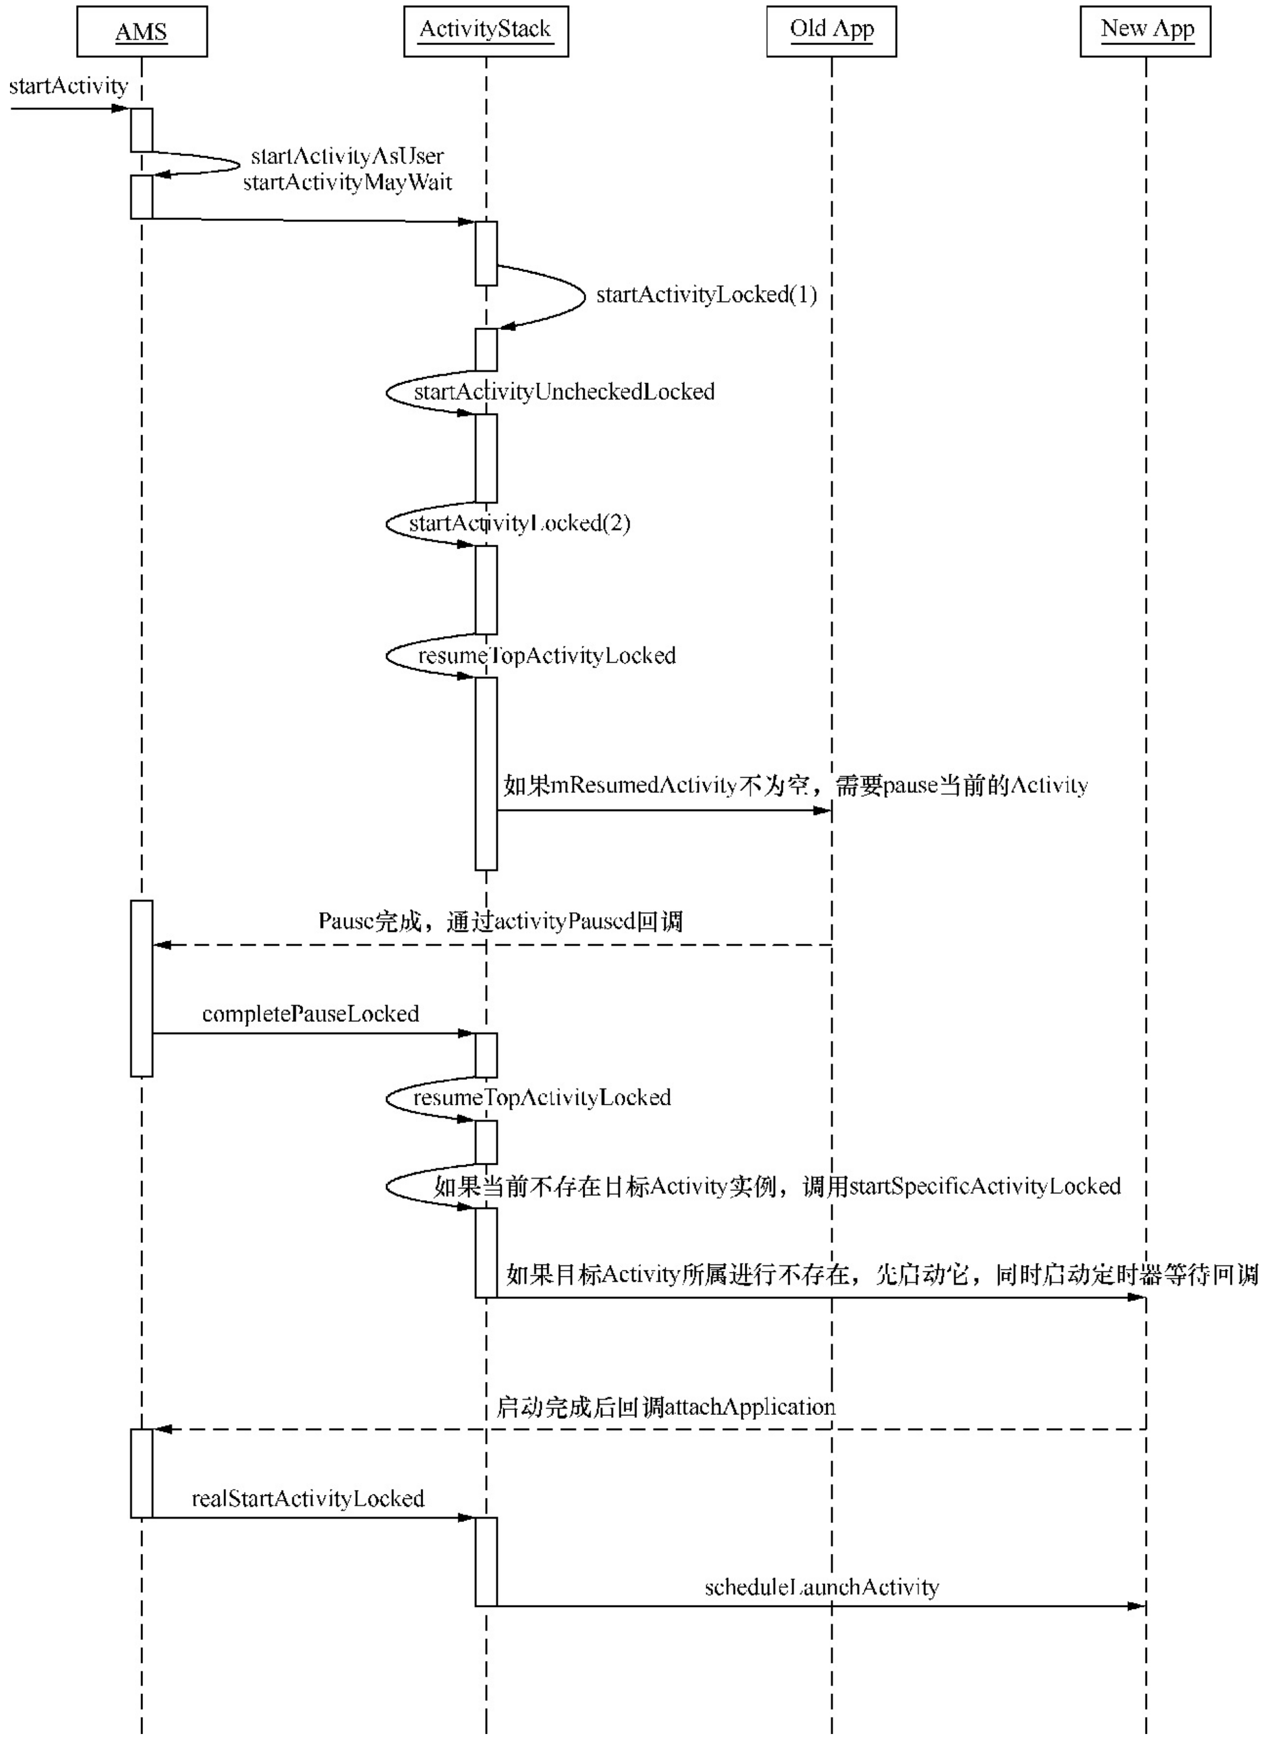

AMS
ActivityStack
Old App
New App
startActivity
startActivityAsUser
startActivityMayWait
startActivityLocked(1)
startActivityUncheckedLocked
startActivityLocked(2)
resumeTopActivityLocked
如果mResumedActivity不为空，需要pause当前的Activity
Pause完成，通过activityPaused回调
completePauseLocked
resumeTopActivityLocked
如果当前不存在目标Activity实例，调用startSpecificActivityLocked
如果目标Activity所属进行不存在，先启动它，同时启动定时器等待回调
启动完成后回调attachApplication
realStartActivityLocked
scheduleLaunchActivity

▲图8-5　AMS中startActivity流程图

值得一提的是，随着NDK的不断完善，目前Android已经支持纯C/C++语言实现的App了，即NativeActivity。NDK目录下的samples\native-activity就是一个很好的例子，如下所示：

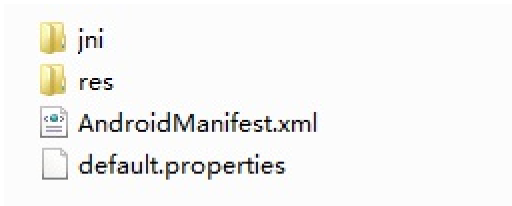

可以看到，纯C/C++工程结构的最大变化就是src和res文件夹没有了。而AndroidManifest.xml中会有如下声明：

```
        <activity android:name="android.app.NativeActivity"
                android:label="@string/app_name"
                android:configChanges="orientation|keyboardHidden
<!-- Tell NativeActivity the name of or .so -->
            <meta-data android:name="android.app.lib_name"
                    android:value="native-activity" />
```

看上去是不是和Java实现方案中的Activity很类似？没错，事实上Android系统只是通过一个预先实现的“android.app.NativeActivity”作为中转，为开发者省去了人工编写调用本地代码的“Java壳”的麻烦——而从应用程序内部原理来说是“换汤不换药”。

那么C/C++的入口地址在哪里呢？

答案是android_main。NativeActivity在onCreate时会去加载上述meta-data中指定的so库，并在其中查找名为“ANativeActivity_onCreate”的函数实现。这个函数不但会为本地层代码运行创建一个新线程，而且会调用到android_main，这样一来就进入到应用程序自定义的C/C++处理逻辑中了。

和SDK一样，NDK也提供了丰富的API来供应用程序使用。开发者需要include模块的头文件，并在Android.mk中导入相应的so库。这些资源被集中放置在NDK的platforms目录下（根据API等级和机器平台来分

类），如图8-6所示。

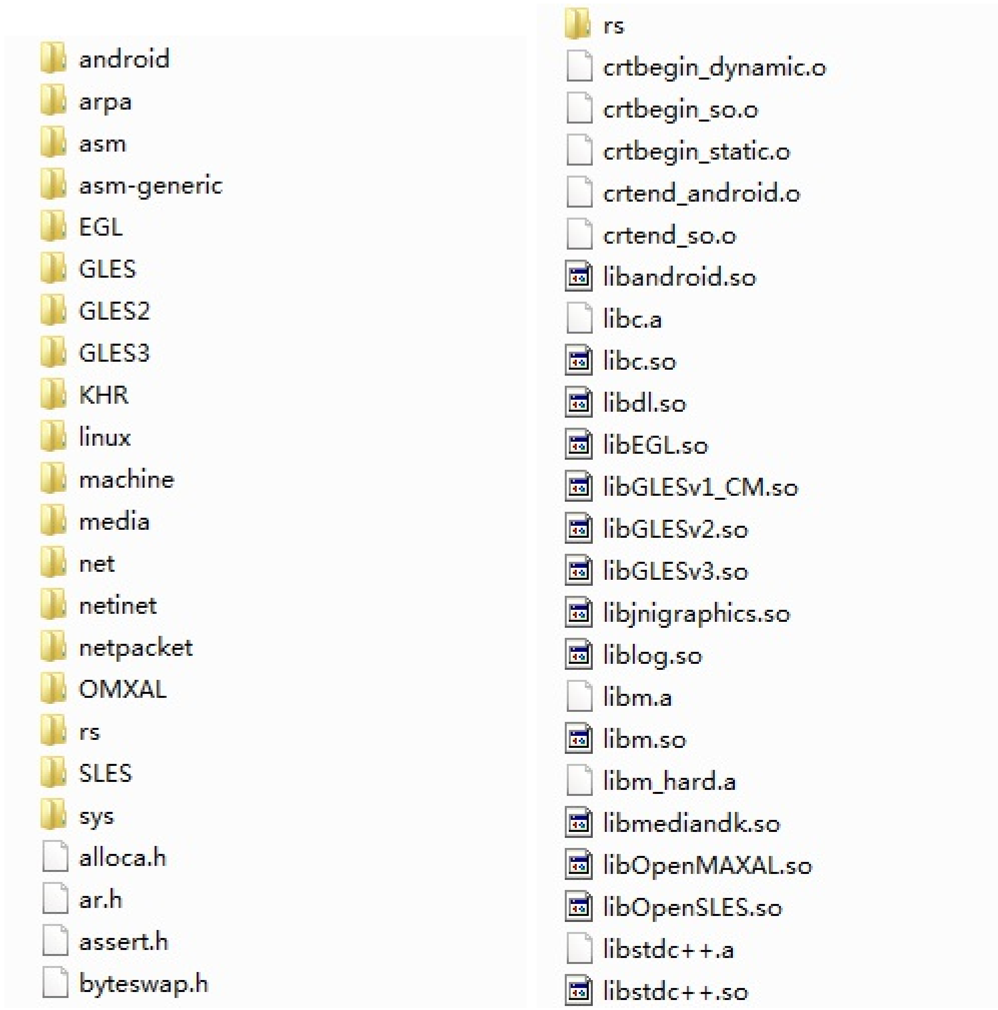

▲图8-6　NDK提供的头文件和库资源

8.4　完成同一任务的“集合”——Activity Task

Android系统中应用程序的一大特色，就是它们不仅可以“装载”众多系统组件，而且可以把这些组件跨进程地组成ActivityTask。这个特性使得每个应用都不是孤立的，从而能最大限度地实现资源复用。举个例子，一个短信应用程序至少会有“已收短信列表”、“阅读短信”和“编辑短信”3个子功能——在Android体系中它们分别对应3个Activity。

从程序包（Package）的组织角度来说，这3个元素只属于“短信”这个程序。但事实上，Activity的设计意图已经超越了单一的进程概念。换句话说，这几个Activity不仅在“短信”这一程序可以非常方便地互相调用（比如用户在“已收短信列表”中点击任何一条短信就可以进入“短信阅读”），其他需要使用“短信”功能的进程也能通过startActivity(Intent)来复用它们。比如我们在浏览电话本时，可以将某个人的联系方式通过短信发送出去。电话本程序并不需要专门实现短信的编辑和发送，只需填写这一请求（Intent），然后利用startActivity(Intent)告诉系统，余下的事情就会有相应的“志愿者”去帮它完成。

在这一过程中，系统先后启动了“联系人详情”和“短信编辑”两个不同进程中的Activity，来共同完成“通过短信发送联系人信息”的任务，这就是ActivityTask概念的直观体现。从数据结构的角度来讲，Task有先后之分，所以源码实现上采用了Stack栈的方式。在本例中，“联系人详情”这个Activity是首先启动并被压栈的，随后“栈顶”的位置被“短信编辑”所取代——直到短信发送完成后被销毁，此时就又会“显示”出原来的那个“联系人详情”的Activity了。

可以看到，采用ActivityTask的处理过程不但符合用户的逻辑思维和使用习惯，并且可以极大地复用系统中的资源。如果当前系统中已经安装了多种同功能的应用程序（比如有多款“短信”应用存在），还可以丰富用户的选择（当然如果Contacts应用中自带了短信编辑和发送功能，并强制用户使用，那么用户就没有其他选择了），如图8-7所示。

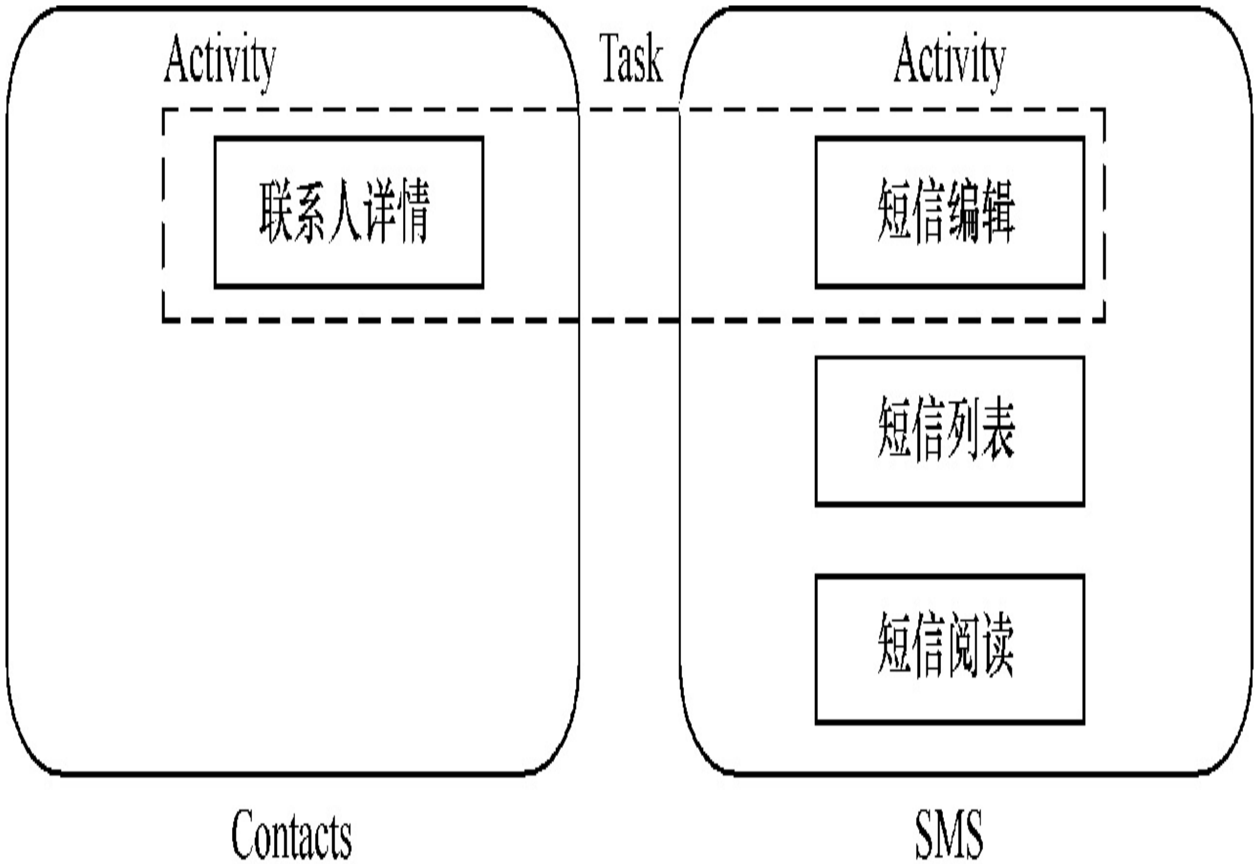

▲图8-7　ActivityTask实例

ActivityTask机制打破了应用程序的常规使用界限，从而增强了用户体验。同时，也给程序的管理和实现增加了一定难度。上面已经说过，Task运用的是“栈”管理方式，那么在AMS中具体是如何实现的呢？当前系统应该不仅有一个Task，而是众多Task的集合，这些Task间又有什么联系？用户是否可以控制和调整这些Task间的联系呢？

回答是肯定的。Android系统提供了一系列Flag标志来允许用户对Task进行实时调整，正确理解和使用这些flag无疑会让应用程序更贴近用户的使用习惯。接下来我们将做统一的讲解。

8.4.1　“后进先出”——Last In，First Out

传统意义上“栈”的思想就是“Last In, First Out”。通俗地讲，就是“后进先出”——先入栈的元素会被压在栈底，而后续元素不断往上堆栈。因而出栈时自然是最后的那个元素在先，然后才是下面的元素，直到栈底。

从上述“栈”的概念来衡量，ActivityTask并不能算是严格意义的Stack——它在默认情况下和栈是一致的，但比栈提供了更多的操作方式，因而可以理解为“栈的一种变异”。

我们再举个例子来描述下Android系统中ActivityTask“栈”的演变过程。

假设在“短信编辑”这个Activity中，用户又启动了另一个Activity“选择表情”，那么Activity Task的变化如图8-8所示。

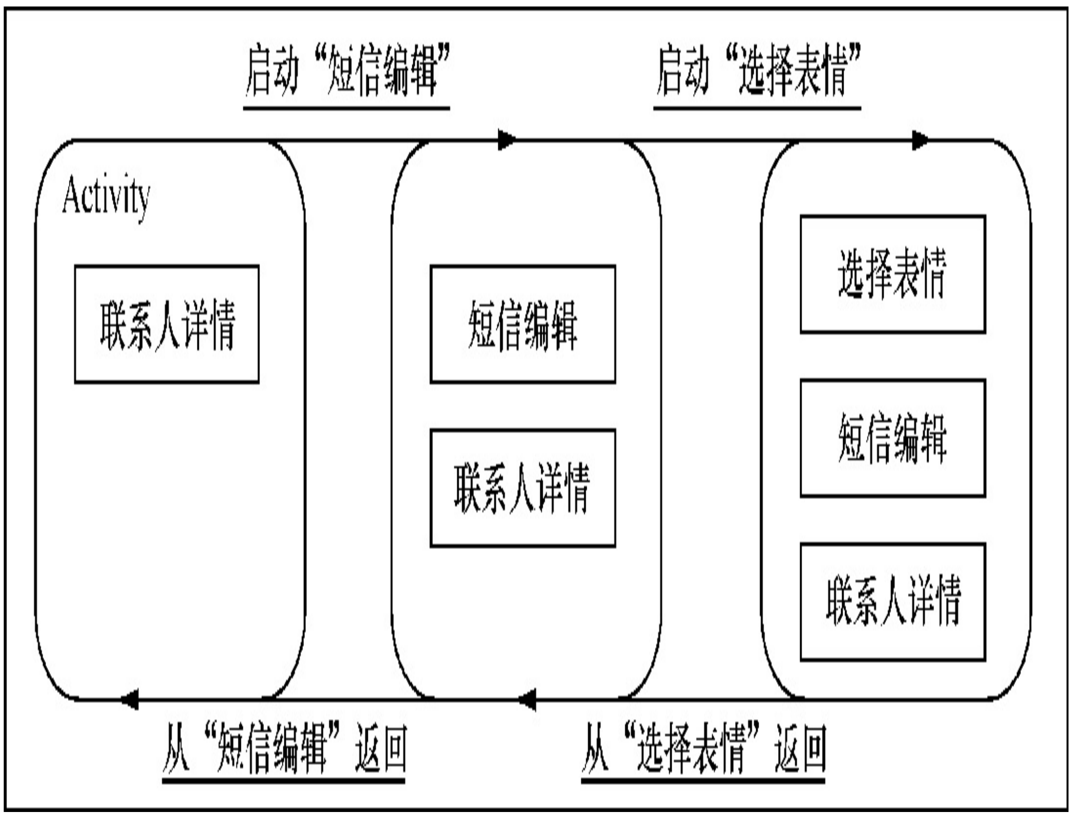

▲图8-8 Activity Task的演变

在本例中，当分别启动“短信编辑”和“选择表情”这两个Activity时，Activity Task先后把它们压入栈中。这样一旦用户选择了返回（比如按了BACK键），栈顶的元素就会被自动销毁，然后开始显示新的栈顶元素。在“将联系人信息发送出去”这一任务的整个执行过程中，用户并不会明显感觉到应用程序间的切换，而会认为“短信编辑”和“选择表情”也是属于第一个应用程序的。

8.4.2 管理Activity Task

前一小节所述的Activity Task已经能满足开发者的一般需求，但是在某些情况下我们还希望拥有更多的灵活性。比如在启动一个新的Activity时，我们可能不希望它和当前的Activity处于同一个Task中；或者我们希望当新的Activity运行时，系统可以先清空当前的Task等。Android系统提供了丰富的接口方法来满足程序员的类似需求——前面讲解startActivity时大家也已经有过接触，本小节将做更详尽的介绍。

应用程序可以通过两种方法来影响Activity Task的默认行为。

方法1：在<activity>标签中指定属性

相关的标签属性如下所示。

- android:taskAffinity

Affinity即“喜好，倾向”，它代表这个Activity所希望归属的Task。在默认情况下，同一个应用程序中的所有Activity拥有共同的Affinity，即<AndroidManifest.xml>中声明的Package Name。当然也可以主动在<application>中使用taskAffinity标签属性来指定整个应用程序的Affinity。

一个Activity Task的Affinity属性取决于它的根Activity。

那么，taskAffinity在什么情况下产生效果？

（1）当启动Activity的Intent中带有FLAG_ACTIVITY_NEW_TASK标志时。

在默认情况下，目标Activity将与startActivity的调用者处于同一Task中。但如果用户特别指定了FLAG_ACTIVITY_NEW_TASK，表明它希望为Activity重新开设一个Task。这时就有两种情况：假如当前已经有一个Task，它的affinity与新Activity是一样的，那么系统会直接用此Task来完成操作，而不是另外创建一个Task；否则系统需要重启一个Task。

（2）当Activity中的allowTaskReparenting属性设置为true时。

在这种情况下，Activity具有“动态转移”的能力。举个前面的“短信”例子，在默认情况下该应用程序中的所有Activity具有相同的affinity。当另一个程序启动了“短信编辑”时，一开始这个Activity和启动它的Activity处于同样的Task中。但如果“短信编辑”Activity指定了allowTaskReparenting，且后期“短信”程序的Task转为前台，此时“短信编辑”这一Activity会被“挪”到与它更亲近的“短信”Task中。

- android:launchMode

用于指定Activity被启动的方式。主要包括两方面的内容：即Activity是否为单实例以及Activity归属的Task。根据经验，不少开发者认为launchMode比较容易混淆，所以建议大家牢记一点——不论是何种方式，最终被启动的Activity通常情况下都要位于Activity Task的栈顶（因为只有在栈顶的Activity才是可以直接与用户交互的）。一共有4种launchMode，如表8-3所示。

表8-3　　launchMode释义

android:launchMode	Description
standard	默认状态。这种模式下Activity是多实例的，意味着系统总是启动一个新的Activity来满足要求——即便之前已经存在该Activity的实例；并且它归属于调用startActivity将其启动的那个task（除非Intent中明确指明FLAG_ACTIVITY_NEW_TASK，下面我们会讲到）
	这个模式和上面的standard非常类似，它也表明Activity是多实例（除下面的情况）的，且task的归属也一致。区别在

singleTop	于： 对于standard，无论何时它都会生成一个新的Activity实例；而singleTop当遇到目标Activity已经存在于目标task的栈顶时，会将Intent通过onNewIntent传给这个Activity而不是生成一个新的实例
singleTask	从名称可以看出来，它表明Activity是单实例的，Intent将通过onNewIntent传送给已有的实例；而且它总是在一个新的task中启动。换句话说，这种类型的Activity永远在task的根位置。另外，singleTask允许其他Activity进驻到它所在的task中，这一点和下面的singleInstance不同
singleInstance	和singleTask基本一致，不过它不允许其他Activity进驻到它所属的task中。也就是说，singleInstance永远都是在一个孤立的task中

- android:allowTaskReparenting

这个属性前面讲解过。如果Activity没有单独指定这个值，那么它们将继承<application>中的描述。

- android:clearTaskOnLaunch

清除Task中所有除root activity的元素。可想而知这个属性只对root activity设置有效，task中其他activity设置此属性是无效的。

- android:alwaysRetainTaskState

如果用户在一定时间内不再访问Task，比如说30分钟，那么系统就有可能会清除task中的状态（只保留root activity）。设置此属性

为“true”可以避免这种情况。

- android:finishOnTaskLaunch

当Task被再次启动时，activity是否需要销毁。这个属性比allowTaskReparenting优先级高。也就是说，这种情况下activity不会被重新指定task，而是直接销毁。

方法2：使用Intent标志

除了在标签中声明task属性外，我们也可以在启动一个Activity(startActivity)时通过Intent来动态指定所需的task属性值。大家可能会有疑惑，Activity中静态标注的属性和后面startActivity所指定的Intent不是会有冲突吗？没错，确实会发生这种情况。不过就像交通规则一样，交警的实时手势永远优先于路面标志，因而如果真的有冲突则以Intent为准即可。

我们来看看Intent中可以指定哪些与Task相关的控制信息。

- FLAG_ACTIVITY_NEW_TASK

这个和前面的singleTask启动模式的作用是一样的。

- FLAG_ACTIVITY_SINGLE_TOP

这个和前面的singleTop启动模式的作用是一样的。

- FLAG_ACTIVITY_CLEAR_TOP

和上面两个不同，launchMode中没有与此对应的模式。它所代表的含义是：如果要启动的Activity已经在当前task中运行，那么所有在它之上的Activity都将被销毁，并且Intent通过onNewIntent传给它（这时它会被resumed）。

另外还有几个Intent标志对我们分析AMS有帮助，一并列出如下。

- FLAG_ACTIVITY_NO_HISTORY

这个Activity将不会被保存在History Stack中。同样的效果也可以通过在AndroidManifest.xml中添加“android:noHistory”来实现。

- FLAG_ACTIVITY_MULTIPLE_TASK

这个标志需要和FLAG_ACTIVITY_NEW_TASK一同使用，否则没有效果。它将阻止系统恢复一个现有的task（比如我们要启动的Activity已经在这个Task中）。换句话说，系统总是启动一个新的task来容纳要启动的Activity。

- FLAG_ACTIVITY_EXCLUDE_FROM_RECENTS

如果设置了这个标志，则Activity不会被放在系统“最近启动的Activity列表”中。

- FLAG_ACTIVITY_BROUGHT_TO_FRONT

在launchMode中使用了singleTask后，系统会自动加上这个标志。

- FLAG_ACTIVITY_RESET_TASK_IF_NEEDED

使用此标志，当Activity在新task中启动或者在已有task中启动，都会处于task的上端。

- FLAG_ACTIVITY_LAUNCHED_FROM_HISTORY

系统自动设置的，说明这个Activity是从历史记录中启动的（长按HOME键可以调出）。

- FLAG_ACTIVITY_CLEAR_WHEN_TASK_RESET

一般情况下，当从Launcher启动应用程序Activity时都带有FLAG_ACTIVITY_RESET_TASK_IF_NEEDED，这样Task中所有此Activity上面的Activity都将被finish。这个标志就是辅助完成这个功能的。

- FLAG_ACTIVITY_NO_USER_ACTION

Activity中的onUserLeaveHint回调用于指示用户将要离开，它会

退出前台。某些情况下这并不是用户主动选择造成的。比如当系统有来电（Incoming Call）或者闹钟事件，由此弹出的Activity都不是用户主动去点击启动的，因而带上这个标志可以使前述的回调函数不得到执行。

- FLAG_ACTIVITY_REORDER_TO_FRONT

设置此标志后，如果将要启动的Activity已经在History Stack中运行，那么我们只是调整其中的顺序将其放到最前端。

- FLAG_ACTIVITY_NO_ANIMATION

此标志表示启动的Activity不需要应用动画效果。

- FLAG_ACTIVITY_CLEAR_TASK

此标志将清除与启动的Activity相关task中的其他元素，只能与FLAG_ACTIVITY_NEW_TASK一起用。

- FLAG_ACTIVITY_TASK_ON_HOME

新启动的Activity将被放在task中Launcher的上面（如果存在的话），这样它返回时就会是Launcher了。此标志只能与FLAG_ACTIVITY_NEW_TASK一起用。

8.5 Instrumentation机制

谈及“Instrumentation”，读者的第一印象可能是自动化测试。这确实是它在Android开发中的一个典型应用场景，不过Instrumentation还有其他不少强大的功能。合理利用Instrumentation有时可以产生意想不到的效果——譬如迫使两个APK运行于同一个进程中，从而达到资源共享的目的。

我们先从用户的角度来讲解如何使用Instrumentation所提供的功能。我们知道，Android系统在/system/bin下提供了很多“中介”程序来允许外部用户间接使用System Service，例如pm、am等。Instrumentation是其中ActivityManager的核心子功能之一，它的语法规则如下：

```
am instrument [-r] [-e <NAME> <VALUE>] [-p <FILE>] [-w] [--user <
```

Android官方对这些选项的释义如表8-4所示。

表8-4　Instrument各选项官方释义

Options	Description
-r	print raw results (otherwise decode REPORT_KEY_STREAMRESULT). Use with [-e perf true] to generate raw output for performance measurements.
-e	set argument <NAME> to <VALUE>.　For test runners a common form is [-e <testrunner_flag> <value>[, <value>...]]
-p	write profiling data to <FILE>

-w	wait for instrumentation to finish before returning. Required for test runners
--user	Specify user instrumentation runs in current user if not specified
--no-window-animation	turn off window animations while running
--abi	Launch the instrumented process with the selected ABI.This assumes that the process supports the selected ABI

其中“-e”用于指定额外的参数，如下所示的常用范例：

```
adb shell am instrument -e class com.lxs.instrument.TestCase -w c
```

另外，在作为测试工程使用时，<COMPONENT>对应的是<TEST_PACKAGE>/<RUNNER_CLASS>。下面我们重点关注“-e”和<COMPONENT>的处理流程。

用户发起的“am instrument”调用命令将由runInstrument@am.java负责解析，其中与<COMPONENT>相关的语句如下：

```
        String cnArg = nextArgRequired();
        ComponentName cn = ComponentName.unflattenFromString(cnAr
```

变量cnArg代表的是Component字符串，它可以通过unflattenFromString转化为一个ComponentName对象。“Unflatten”的规则很简单，就是以“/”为分隔符：前半部分成为Package，剩余的就是Class。

“-e”后面跟随的所有[Name, Value]将被保存到一个Bundle对象

中，并和其他参数一起最终传递给ActivityManagerService。后者会在与承载进程建立关联后（请参考本书其他章节的分析），由BindApplication@ActivityThread来处理这些参数：

```
/*frameworks/base/core/java/android/app/ActivityThread.java*/
    private void handleBindApplication(AppBindData data) {…
        if (data.instrumentationName != null) {//instrumentationN
            InstrumentationInfo ii = null;
            try {
                ii = appContext.getPackageManager().
                    getInstrumentationInfo(data.instrumentationNa
            } catch (PackageManager.NameNotFoundException e) {
            }
            …
            mInstrumentationPackageName = ii.packageName;
            …
            LoadedApk pi = getPackageInfo(instrApp, data.compatIn
                    appContext.getClassLoader(), false, true, fal
            ContextImpl instrContext = ContextImpl.createAppConte

            try {
                java.lang.ClassLoader cl = instrContext.getClassL
                mInstrumentation = (Instrumentation)
                    cl.loadClass(data.instrumentationName.getClas
            } catch (Exception e) {…
            }
            mInstrumentation.init(this, instrContext, appContext,
                   new ComponentName(ii.packageName, ii.name), da
                   data.instrumentationUiAutomationConnection);
            …
        } else {
            mInstrumentation = new Instrumentation();
        }
    …
        try {
            Application app = data.info.makeApplication(data.rest
            mInitialApplication = app;
            …
            try {
                mInstrumentation.onCreate(data.instrumentationArg
            }
            catch (Exception e) {…
            }
            try {
                mInstrumentation.callApplicationOnCreate(app);
            } catch (Exception e) {…
            }
```

```
        } finally {
            StrictMode.setThreadPolicy(savedPolicy);
        }
    }
```

AppBindData中保存了与应用程序启动相关的所有关键数据，其中data.instrumentationArgs对应的是“am instrument”命令中“-e”所指定的额外参数；而data.instrumentationName对应的是“am instrument”命令中的<COMPONENT>，我们可以根据这个参数构造出用户指定的Instrumentation对象(例如android.test.InstrumentationTestRunner)。当然，如果应用程序并没有Instrumentation组件，那么系统会使用默认的Instrumentation类。

由handleBindApplication的处理逻辑不难发现，一个Instrumentation对象的生命周期包括但不限于：

```
newInstance-> init-> onCreate->onStart-> callApplicationOnCreate-->callActivityXXX->onDestroy->…
```

这就是我们在本小节开头所说的，Instrumentation并不是单纯作为一个测试框架存在的。事实上，Android官方对它的定义是：

“Base class for implementing application instrumentation code. When running with instrumentation turned on, this class will be instantiated for you before any of the application code, allowing you to monitor all of the interaction the system has with the application. An Instrumentation implementation is described to the system through an AndroidManifest.xml's <instrumentation> tag.”

换句话说，Instrumentation提供了一种允许用户获取（及改变）应用程序与系统之间的交互流程的机制。自动化测试框架可以看成是这种机制的一种典型的应用形式，但绝不是全部。InstrumentationTestRunner的原理框架如图8-9所示。

值得一提的是，在用户没有特别指定自己的Instrumentation的情况下，它的很多行为都是“伪实现”或者是“透传”。“伪实现”通常针对的是那些Instrumentation自身的行为，譬如onCreate就

是“空”的：

```
/*frameworks/base/core/java/android/app/Instrumentation.java*/
    public void onCreate(Bundle arguments) {//空实现
}
```

而“透传”则主要面向那些对应用程序元素进行控制的行为，例如callActivityOnPause：

```
    public void callActivityOnPause(Activity activity) {
        activity.performPause();//默认情况下，将直接调用Activity元素的
}
```

它们之间的关系可以用图8-10来表示。

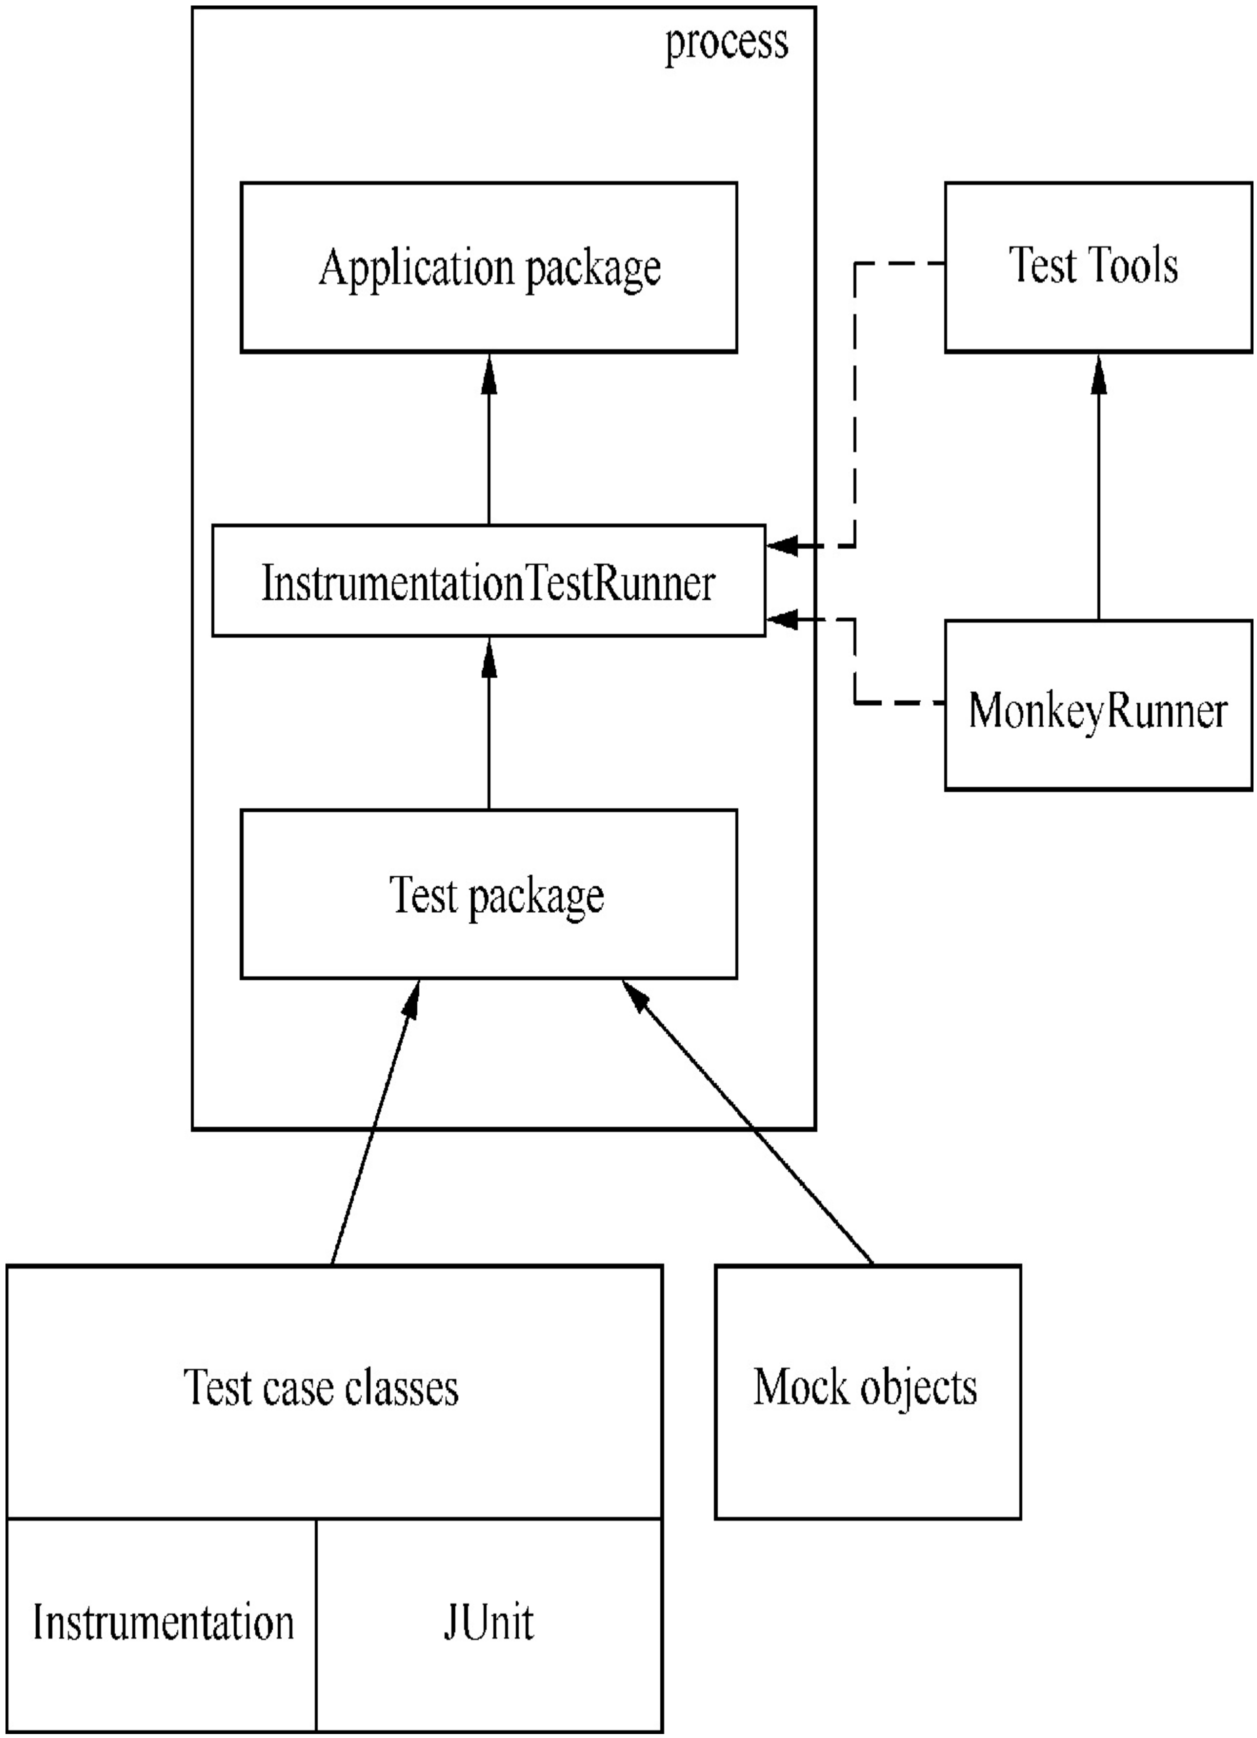
process
Application package
Test Tools
InstrumentationTestRunner
MonkeyRunner
Test package
Test case classes
Mock objects
Instrumentation
JUnit

▲图8-9　InstrumentationTestRunner原理框架

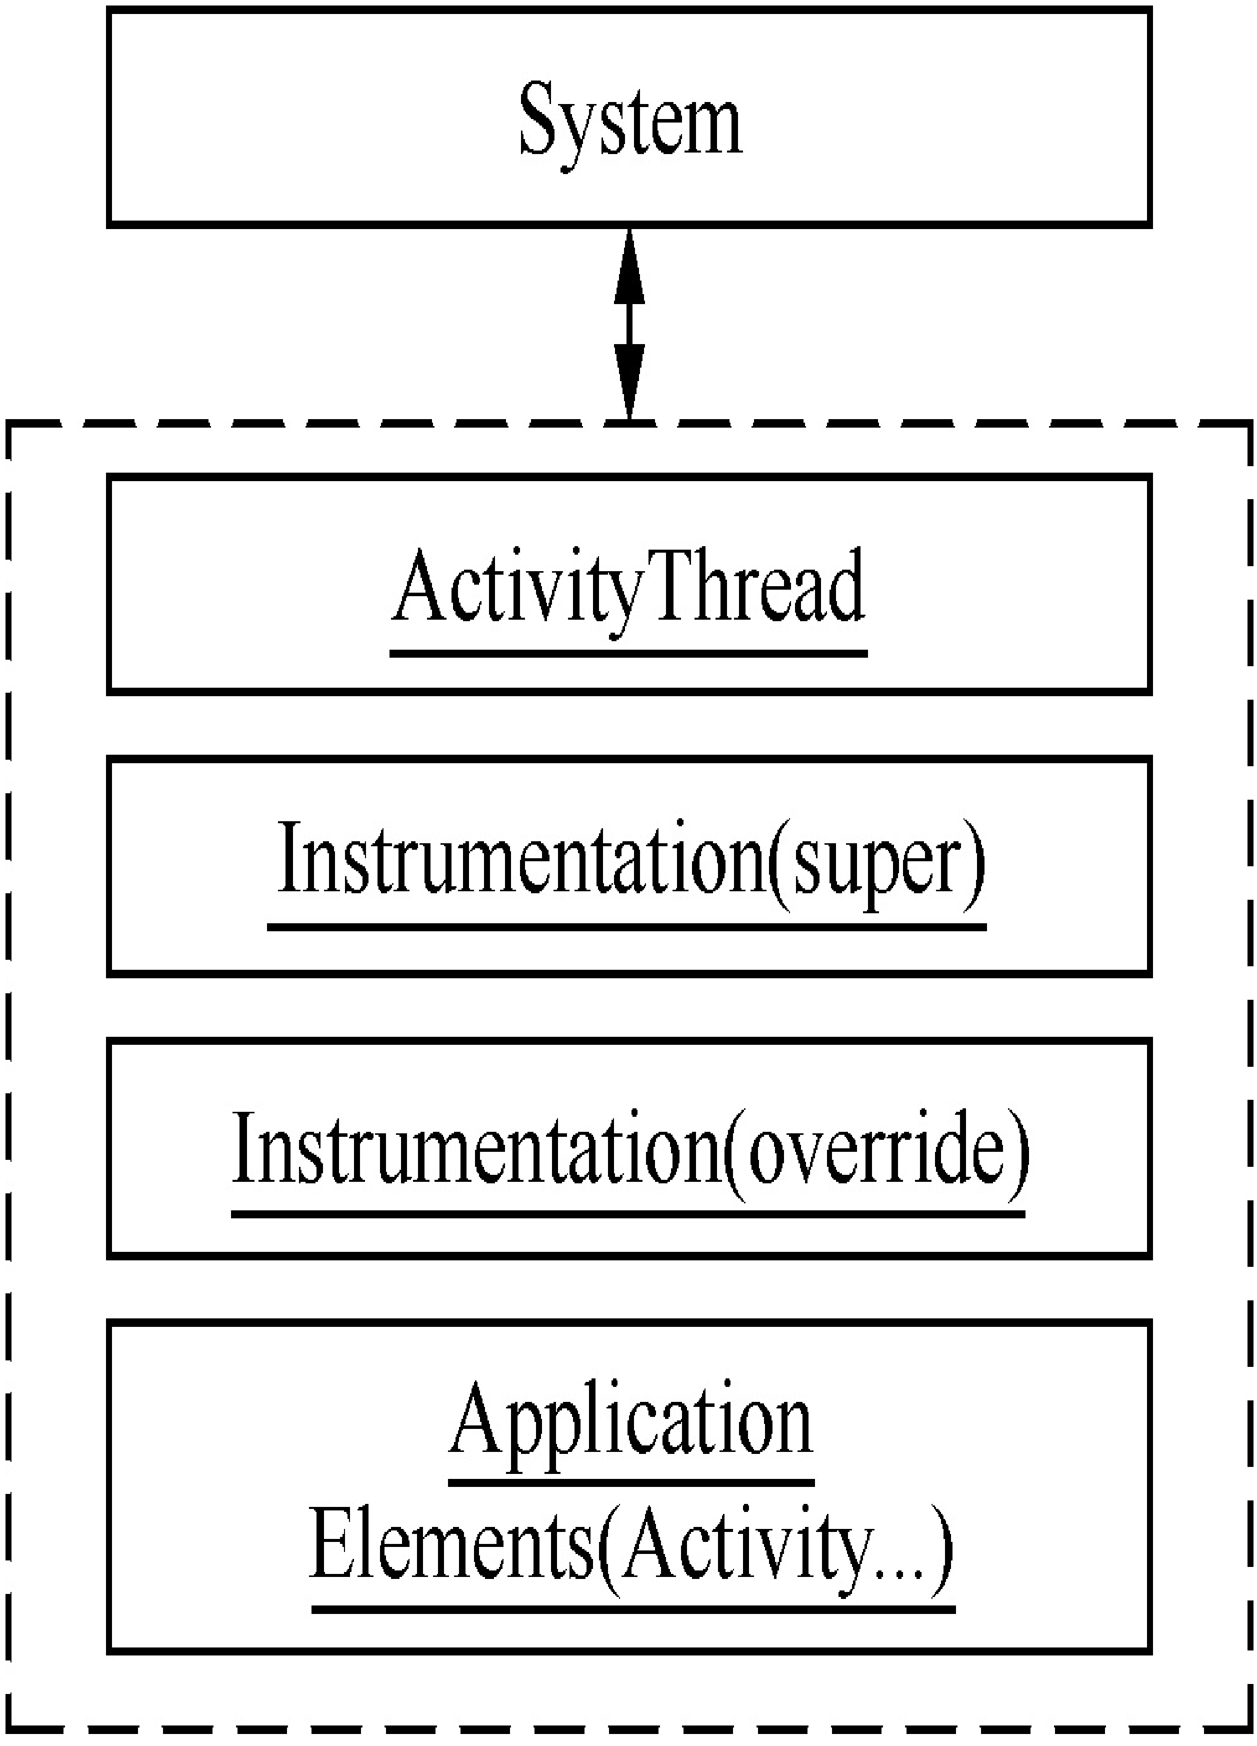

System
ActivityThread
Instrumentation(super)
Instrumentation(override)
Application
Elements(Activity...)

▲图8-10

Instrumentation和ActivityThread显然是运行于同一进程之中，那么它们是否还处于同一个线程中呢？答案是看情况——默认情况下的确如此，但Instrumentation还同时提供了一个start函数来将自己“腾挪”到新线程中开展工作，以免给应用程序“造成不必要的麻烦”：

```
/*frameworks/base/core/java/android/app/Instrumentation.java*/
public void start() {
        if (mRunner != null) {
            throw new RuntimeException("Instrumentation already s
        }
        mRunner = new InstrumentationThread("Instr: " + getClass(
        mRunner.start();
    }
```

从上述代码段中可以看到，我们需要首先调用start函数来生成一个名为InstrumentationThread的新线程。因为这个线程在启动后还会回调onStart，所以自定义的Instrumentation类所需完成的工作可以放在这个函数中实现。

除了本小节所阐述的内容外，Instrumentation机制还有很多细节值得我们去推敲，建议大家可以结合InstrumentationTestRunner和以下各类TestCase来做深入挖掘学习：

- ActivityInstrumentationTestCase2；
- ActivityUnitTestCase；
- AndroidTestCase；
- ApplicationTestCase；
- InstrumentationTestCase；
- ProviderTestCase；
- ServiceTestCase；
- SingleLaunchActivityTestCase。

第9章 GUI系统——SurfaceFlinger

GUI（Graphical User Interface）即“图形用户界面”，可以说在任何Operating System中都占据着非常重要的位置，因为它是用户对操作系统最直接的“感官”体验。一款优秀的图形界面系统至少要满足以下几个条件。

- 流畅性

我们认为评判一款GUI系统优劣的重要准则之一，就是流畅性。历史经验表明，即便再“炫酷”的UI界面，一旦出现经常性的画面“滞后”，最终都会被用户所抛弃。Google在这一方面既是“饱受煎熬”——Android系统的流畅性长期以来就是媒体诟病的焦点之一；同时也可谓“用心良苦”——后续小节讲述的“Project Butter”就是其众多努力的成果之一。

- 友好性

因为GUI是直接面向终端用户的，可以认为是操作系统的“脸面”。所以一张“和善”的脸，总是会比“凶神恶煞”更“讨喜”。友好性意味着用户操作上的人性化，图形的一致性以及视觉元素上的合理搭配等一系列因素，是一个综合的评判标准。

- 可扩展性

仅有“流畅性”和“友好性”显然还是不够的，GUI的“可扩展性”也同样重要。扩展意味着开发者或用户可以在系统内建的基础上无

限延伸自己的“创意”，如添加新的界面和交互方式、实现更复杂的图形处理功能等。

在进入GUI系统的学习前，建议大家先阅读本书应用篇中“Android和OpenGL ES”章节的介绍，并参阅OpenGL ES的官方指南。因为Android的GUI系统是基于OpenGL/EGL来实现的，如果没有一定的基础知识作为支撑，分析源码时有可能会“事倍功半”。

9.1　OpenGL ES与EGL

SurfaceFlinger虽然是GUI系统的核心，但从OpenGL ES的角度来讲，其实只能算是一个“应用程序”。

对于没有做过OpenGL ES开发的人来讲，理解SurfaceFlinger的内部原理还是有一定难度的。不少读者对系统中既有EGL/OpenGL ES，又有DisplayHardware、Gralloc、FramebufferNativeWindow等一系列陌生的模块感到混乱而无序。

的确如此，假如不先厘清这些模块的相互关系，对于我们深入研究整个Android显示系统将是一个很大的障碍。鉴于此，我们希望先从框架的高度来审视一下它们之间错综复杂、“剪不断理还乱”的依赖关系。

我们按照由“底层到上层”的顺序来逐步分析图9-1中阐述的架构。

（1）Linux内核提供了统一的framebuffer显示驱动。设备节点/dev/graphics/fb*或者/dev/fb*，其中fb0表示第一个Monitor，当前系统实现中只用到了一个显示屏。

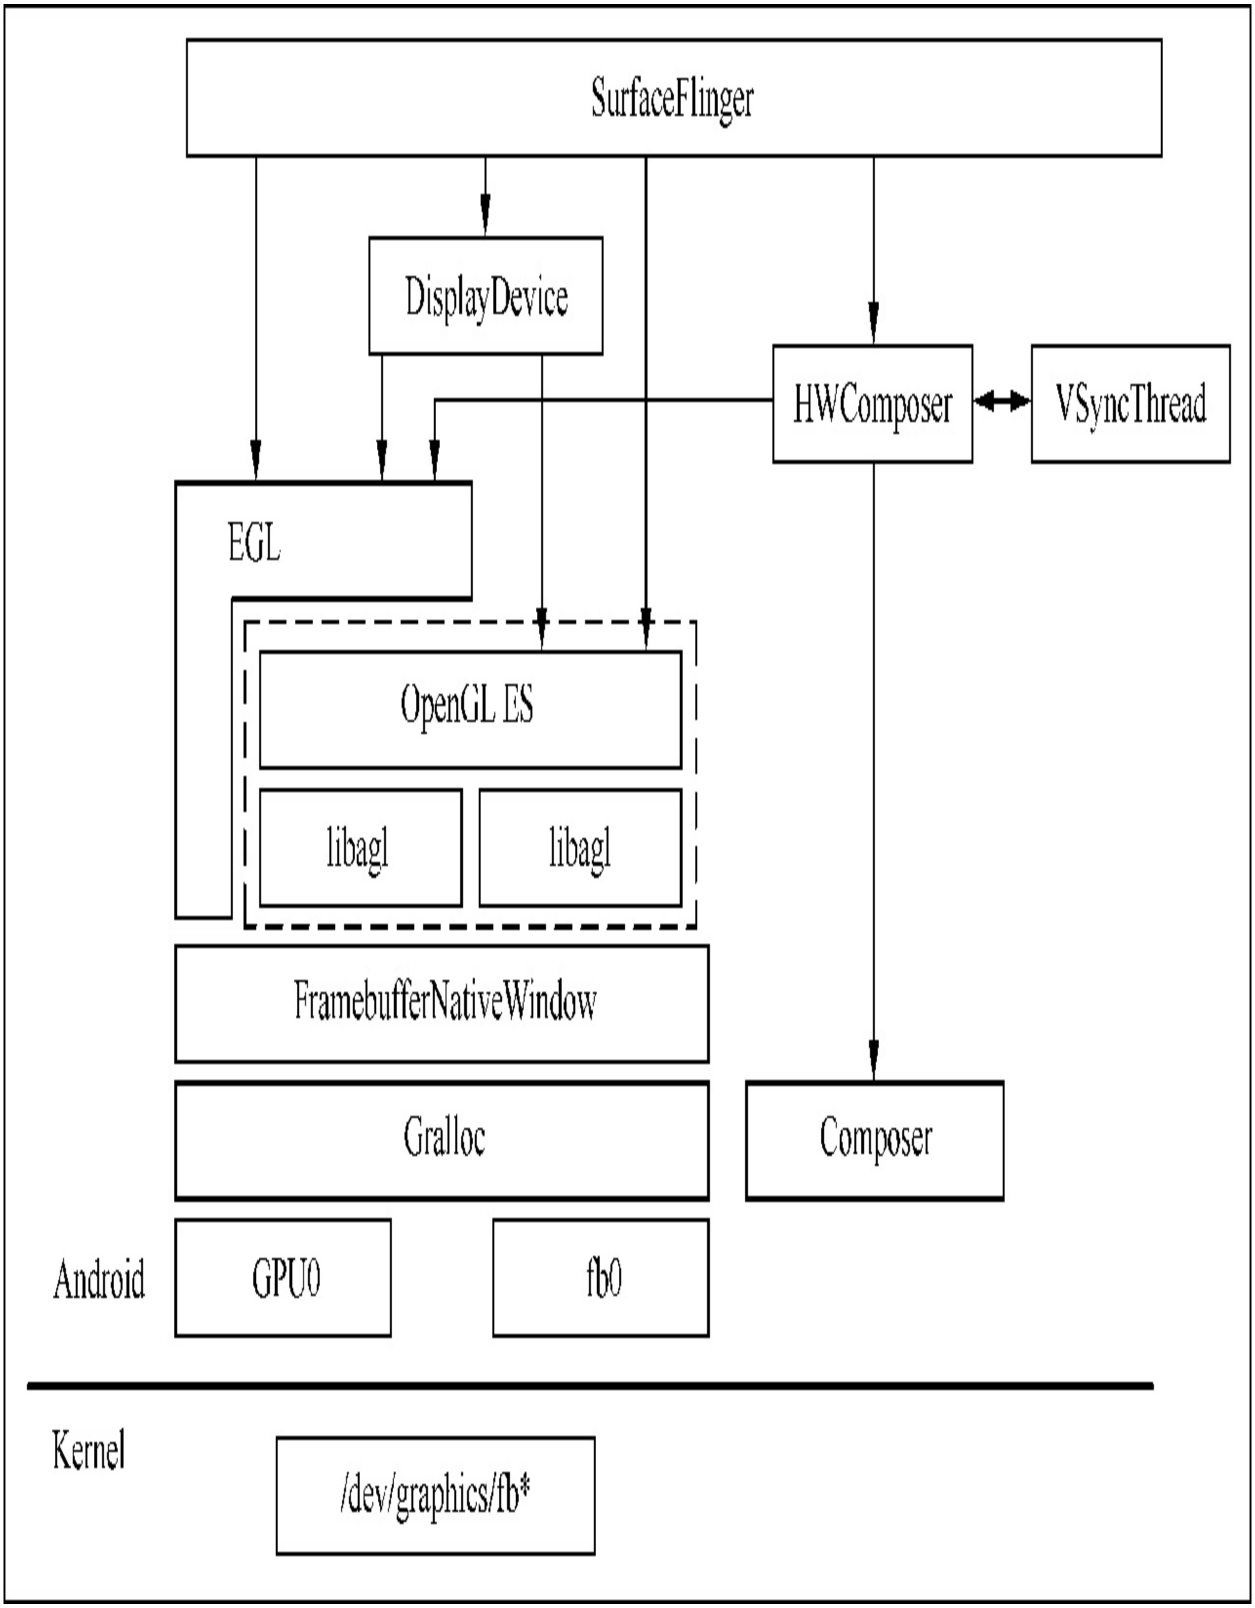

▲图9-1　SurfaceFlinger与OpenGL ES等模块的关系图

（2）Android的HAL层提供了Gralloc，包括fb和gralloc两个设备。前者负责打开内核中的framebuffer、初始化配置，并提供了post、setSwapInterval等操作接口；后者则管理帧缓冲区的分配和释放。这就意味着上层元素只能通过Gralloc来间接访问帧缓冲区，从而保证了系统对framebuffer的有序使用和统一管理。

另外，HAL层的另一重要模块是“Composer”——如其名所示，它为厂商自定制“UI合成”提供了接口。Composer的直接使用者是SurfaceFlinger中的HWComposer（有两个HWComposer，后面我们会详细讲解）——后者除了管理Composer的HAL模块外，还负责VSync信号的产生和控制。VSync则是“Project Butter”工程中加入的一种同步机制，它既可以由硬件产生，也可以通过软件来模拟（VsyncThread），后续有专门的小节进行介绍。

（3）由于OpenGL ES是一个通用的函数库，在不同的平台系统上需要被“本地化”——把它与具体平台中的窗口系统建立起关联，这样才能保证正常工作。从FramebufferNativeWindow这个名称就能判断出来，它就是负责OpenGL ES在Android平台上本地化的中介之一。后面我们还会看到Android应用程序中所使用的另一个“本地窗口”。

为OpenGL ES配置本地窗口的是EGL。

（4）OpenGL或者OpenGL ES更多的只是一个接口协议，具体实现既可以采用软件，也可以依托于硬件。一方面，这给产品开发带来了灵活性——我们可以根据成本与市场定位来决定硬件配置，满足各种用户需求；另一方面，既然有多种实现的可能，那么OpenGL ES在动态运行时是如何取舍的呢？这也是EGL的作用之一。它会去读取egl.cfg这个配置文件，然后根据用户的设定来动态加载libagl（软件实现）或者libhgl（硬件实现）。

（5）SurfaceFlinger中持有一个成员数组mDisplays来描述系统中支持的各种“显示设备”——具体有哪些Display是由SurfaceFlinger在readyToRun中判断并赋值的；并且DisplayDevice在初始化时还将调用eglGetDisplay、eglCreateWindowSurface等接口，并利用EGL来完成对OpenGL ES环境的搭建。

（6）很多模块都可以调用OpenGL ES提供的API（这些接口以“gl”为前缀，如glViewport、glClear、glMatrixMode、

glLoadIdentity等），包括SurfaceFlinger、DisplayDevice等。

（7）与OpenGL ES相关的模块可以分为如下几类。

- 配置类

即帮助OpenGL ES完成配置的，包括EGL、DisplayHardware都可以归为这一类。

- 依赖类

也就是OpenGL ES要正常运行起来所依赖的“本地化”的东西，图9-1中是指Framebuffer NativeWindow。

- 使用类

使用者也可能是配置者，如DisplayDevice既扮演了构建OpenGL ES环境的角色，同时也是它的用户。

如果读者对EGL的使用流程、工作方式还不太清楚，强烈建议先阅读官方文档以及本书应用篇中的相关章节，否则会影响后面的学习和理解。

9.2 Android的硬件接口——HAL

前面章节讲解Android系统框架时曾介绍过HAL的作用，但还没有对其原理进行深入分析。对于Android中很多子系统来说（如显示系统、音频系统等），HAL都是必不可少的组成部分——HAL是这些子系统与Linux Kernel驱动之间通信的统一接口。

HAL需要解决如下问题点。

- 硬件接口抽象

HAL并不是专门针对某个特定的硬件设备来设计的，因而如何从众多类型的设备中提取出它们的共同属性并付诸软件实现是一个关键。

- 接口的稳定性

可想而知，HAL层的接口是不允许频繁更动的，否则就失去了意义。

- 灵活的使用方法

除了上面两点外，HAL还需要提供一套灵活的使用方法，以供硬件开发商及上层使用者定制他们的需求。

本小节接下来将围绕上述3个关键点展开讨论。

1．硬件接口抽象

面向对象的设计思想告诉我们，这里的“抽象”涉及了继承关系——“抽象的硬件”是父类，而“具体的硬件”则是子类。这在C++中很容易实现，但是HAL多数是由C语言实现的，怎么办呢？

其实很简单，只要让子类数据结构的第一个成员变量是父类结构即可。举个Gralloc（后面小节会有详细分析）中的例子，定义如下：

```
/*hardware/libhardware/include/hardware/Gralloc.h*/
/* Every hardware module must have a data structure named HAL_MOD
 * and the fields of this data structure must begin with hw_modul
```

```
 * followed by module specific information.
 */
typedef struct gralloc_module_t {
struct hw_module_t common;//必须以此开头
/*后续部分是此模块的特有数据*/
int (*registerBuffer)(struct gralloc_module_t const* module,buffe
     …
```

从注释中可以看出:

首先，每一个硬件模块都必须有一个名称为HAL_MODULE_INFO_SYM的变量。比如GPS中的实现:

```
struct hw_module_t HAL_MODULE_INFO_SYM = {
    .tag = HARDWARE_MODULE_TAG,//必须以此作为tag
    .version_major = 1,
    .version_minor = 0,
    .id = GPS_HARDWARE_MODULE_ID,
    .name = "Goldfish GPS Module",
    .author = "The Android Open Source Project",
    .methods = &gps_module_methods,
};
```

其次，此变量的数据结构要以hw_module_t（即前面所说的父类）开头，其后的内容才是各硬件模块特有的部分（即子类）。

从效果来看，上面的实现就体现了继承关系，如图9-2所示。

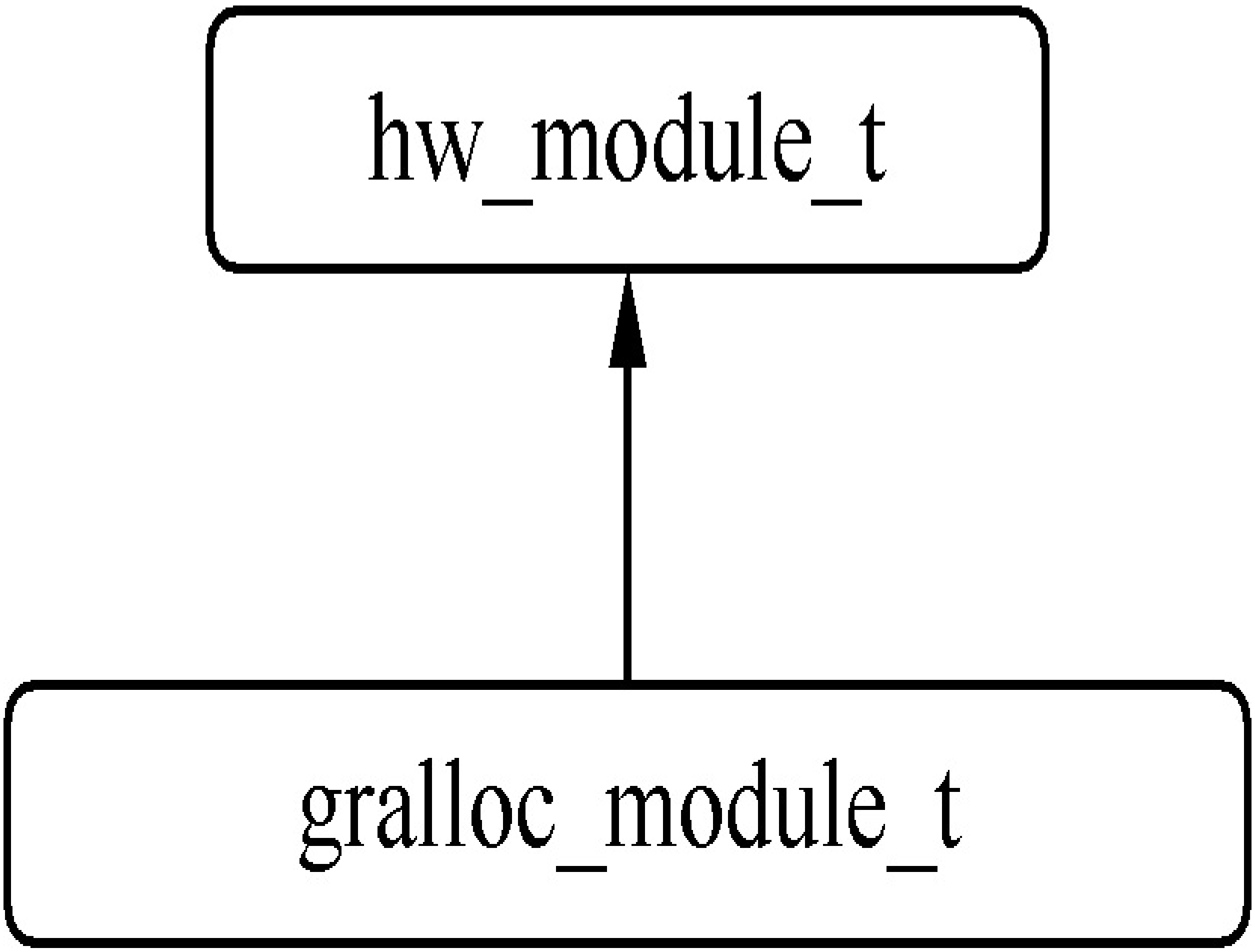

▲图9-2 继承关系

2．接口的稳定性

对于某一类硬件设备来说，它所提供的HAL接口必须是稳定不变的——Android系统已经预先定义好了这些接口，硬件设备商只需要按照要求来“填空”即可。HAL各硬件接口的定义统一放置在工程源码中：

```
hardware/libhardware/include/hardware
```

包括如下几个头文件，如图9-3所示。

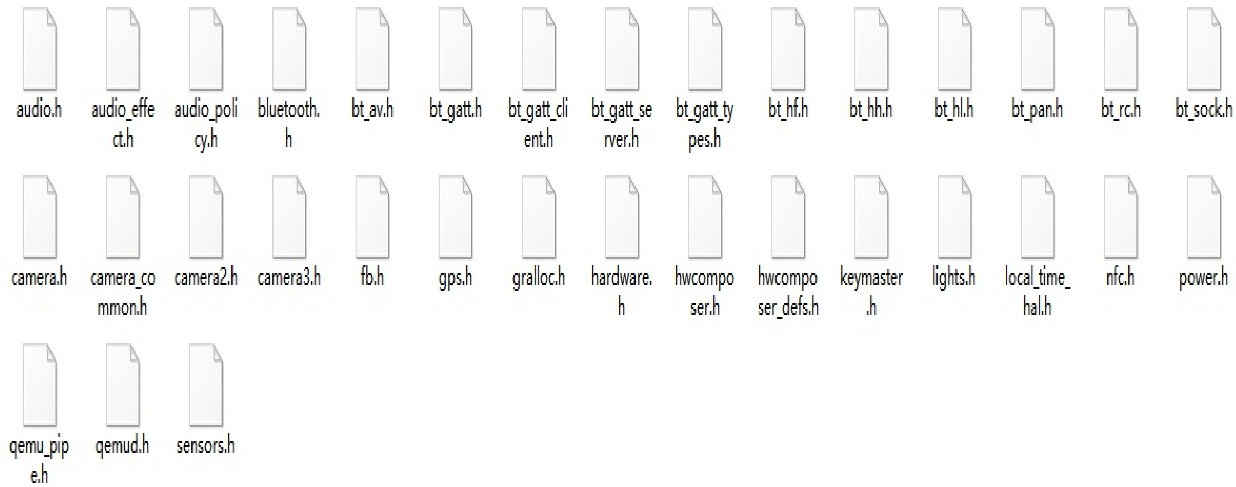

▲图9-3　几个头文件

对于Gralloc来说，它的硬件接口定义如下：

```
typedef struct gralloc_module_t {
    struct hw_module_t common;
    int (*registerBuffer)(struct gralloc_module_t const* module,b
    int (*unregisterBuffer)(struct gralloc_module_t const* module
                         buffer_handle_t handle);
    int (*lock)(struct gralloc_module_t const* module,buffer_hand
            int usage, int l, int t, int w, int h,void** vadd
    int (*unlock)(struct gralloc_module_t const* module,buffer_ha
    int (*perform)(struct gralloc_module_t const* module,int oper
    int (*lock_ycbcr)(struct gralloc_module_t const* module,buffe
          int usage, int l, int t, int w, int h,struct androi
    /* reserved for future use */
    void* reserved_proc[6];
} gralloc_module_t;
```

后续小节会对上述的一些重要接口分别进行讨论。

3．灵活的使用方法

举个例子，两款不同的Android手机设备A与B，它们分别采用了GPS1和GPS2两家厂商的GPS模块。那么需要思考如下几个问题。

- 对于GPS硬件厂商来说

GPS硬件厂商事先并不知道有哪些Android产品会采用它的模块，也

不可能为它们分别维护一套代码；另外，它希望模块的驱动可以同时适配各种不同的Android版本（比如Android4.1、Android4.2、Android4.3和Android4.4）。

此时HAL的优势就体现出来了——GPS厂商（比如GPS1和GPS2）只需要按照Android的要求来实现HAL接口，剩下的事情就迎刃而解了。

- 对于Android手机开发商来说

通常情况下，手机开发商只需要移植GPS硬件厂商提供的HAL库即可（比如GPS1和GPS2的HAL库），其余的事情Android系统会自动完成。

- 对于Android操作系统的开发团队来说

Android系统必须提供完整、可靠并且稳定的HAL机制，来协助上述硬件厂商与手机开发商的工作。

综上所述，当一款GPS模块面向Android市场时，其硬件设计厂商需要按照系统的要求实现HAL接口；后期有手机开发商采用了此模块后，便将此HAL库移植到自己的工程项目中（实际上就是把对应的库文件放置到系统指定的路径中，后面我们还会讲解）；完成上述两个操作后，在设备运行过程中Android的HAL机制将起作用，并主动到指定位置加载此GPS的HAL库。因为HAL的接口是统一的，上层体系并不需要做任何更改就可以成功控制这款GPS模块。

下一小节讲解Gralloc时还会涉及HAL，读者可以结合起来阅读。

9.3 Android终端显示设备的“化身”——Gralloc与Framebuffer

相信做过Linux开发的人对Framebuffer都不会太陌生，它是内核系统提供的图形硬件的抽象描述。之所以称为buffer，是因为它也占用了系统存储空间的一部分，是一块包含屏幕显示信息的缓冲区。由此可见，在“一切都是文件”的Linux系统中，Framebuffer被看成了终端显示设备的“化身”。

另外，Framebuffer借助于Linux文件系统向上层应用提供了统一而高效的操作接口，从而让用户空间中运行的程序可以在不做太多修改的情况下去适配多种显示设备——无论它们属于哪家厂商、什么型号，都由Framebuffer内部来兼容。

在Android系统中，Framebuffer提供的设备文件节点是/dev/graphics/fb*。因为理论上支持多个屏幕显示，所以fb按数字序号进行排列，即fb0、fb1等。其中第一个fb0是主显示屏幕，必须存在。某Android设备的fb节点截图如图9-4所示。

▲图9-4 fb节点截图

Android的各子系统通常不会直接使用内核驱动，而是由HAL层来间接引用底层架构。显示系统中也同样如此——它借助于HAL层来操作帧缓冲区，而完成这一中介任务的就是Gralloc。下面我们分几个方面进行介绍。

1．Gralloc模块的加载

Gralloc对应的模块是由FramebufferNativeWindow（OpenGL ES的本地窗口之一，后面小节有详细介绍）在构造函数中加载的。即：

```
hw_get_module(GRALLOC_HARDWARE_MODULE_ID, &module);
```

函数hw_get_module是上层使用者加载HAL库的入口——这意味着不论是哪个硬件厂商提供的HAL库（比如Gralloc库），我们都只需要通过这个函数来加载它们。

可以看到，针对Gralloc传入的硬件模块ID名为：

```
#define GRALLOC_HARDWARE_MODULE_ID "gralloc"
```

按照hw_get_module的做法，它会在如下路径中查找与ID值匹配的库。

```
#define HAL_LIBRARY_PATH1 "/system/lib/hw"
#define HAL_LIBRARY_PATH2 "/vendor/lib/hw"
```

lib库名有如下几种形式：

```
gralloc.[ro.hardware].so
gralloc.[ro.product.board].so
gralloc.[ro.board.platform].so
gralloc.[ro.arch].so
```

或者当上述系统属性组成的文件名都不存在时，就使用默认的：

```
    gralloc.default.so
```

最后这个default库是Android原生态的实现，源码位置在hardware/libhardware/modules/gralloc/中，它由gralloc.cpp、framebuffer.cpp和mapper.cpp三个主要源文件编译生成。

2．Gralloc提供的接口

Gralloc对应的HAL库被成功加载后，我们来具体看看它所提供的一些重要接口。

根据前一小节的分析，Gralloc是hw_module_t的“子类”。后者定义如下：

```
/*hardware/libhardware/include/hardware/Hardware.h*/
typedef struct hw_module_t {…
    struct hw_module_methods_t* methods;//一个HAL库必须提供的方法
    …
```

```
} hw_module_t;

typedef struct hw_module_methods_t {
    int (*open)(const struct hw_module_t* module, const char* id,
            struct hw_device_t** device);
} hw_module_methods_t;
```

也就是说，任何硬件设备的HAL库都必须实现hw_module_methods_t。目前这个数据结构中只有一个函数指针变量，即open。当上层使用者调用hw_get_module时，系统首先在指定目录中查找并加载正确的HAL库，然后通过open方法来打开指定的设备。

在Gralloc这个例子中，open接口可以帮助上层使用者打开两种设备。分别是:

```
#define GRALLOC_HARDWARE_FB0 "fb0"
```

以及#define GRALLOC_HARDWARE_GPU0 "gpu0"

“fb0”就是我们前面所说的“主屏幕”，gpu0负责图形缓冲区的分配和释放。这两个设备分别由FramebufferNativeWindow中的fbDev和grDev成员变量来管理:

```
/*frameworks/native/libs/ui/FramebufferNativeWindow.cpp*/
FramebufferNativeWindow::FramebufferNativeWindow()
: BASE(), fbDev(0), grDev(0), mUpdateOnDemand(false)
{…
    err = framebuffer_open(module, &fbDev); //打开fb设备
    err = gralloc_open(module, &grDev);//打开gralloc设备
```

上述代码段中的两个open函数由hardware/libhardware/include/hardware目录下的Fb.h和Gralloc.h头文件提供，是打开fb及gralloc设备的便捷实现。可想而知，framebuffer_open和gralloc_open最终调用的肯定还是hw_module_methods_t中的open方法，只是函数参数有所差异——fb对应的设备名为GRALLOC_HARDWARE_FB0；gralloc则是GRALLOC_HARDWARE_GPU0。

Android原生态的Gralloc实现在hardware/libhardware/modules/gralloc中。读者会发现，除了hw_module_t和gralloc_module_t外，各硬件厂商还定义了另一个“私

密”的数据结构，即private_module_t。比如Gralloc中：

```
struct private_module_t {
    gralloc_module_t base;//gralloc_module_t中的第一个元素是hw_modul
    struct private_handle_t* framebuffer;
    uint32_t flags;
    …
}
```

private_module_t从名称上可以看出来，它是该硬件厂商私密的数据部分。因而整个“继承”关系如图9-5所示。

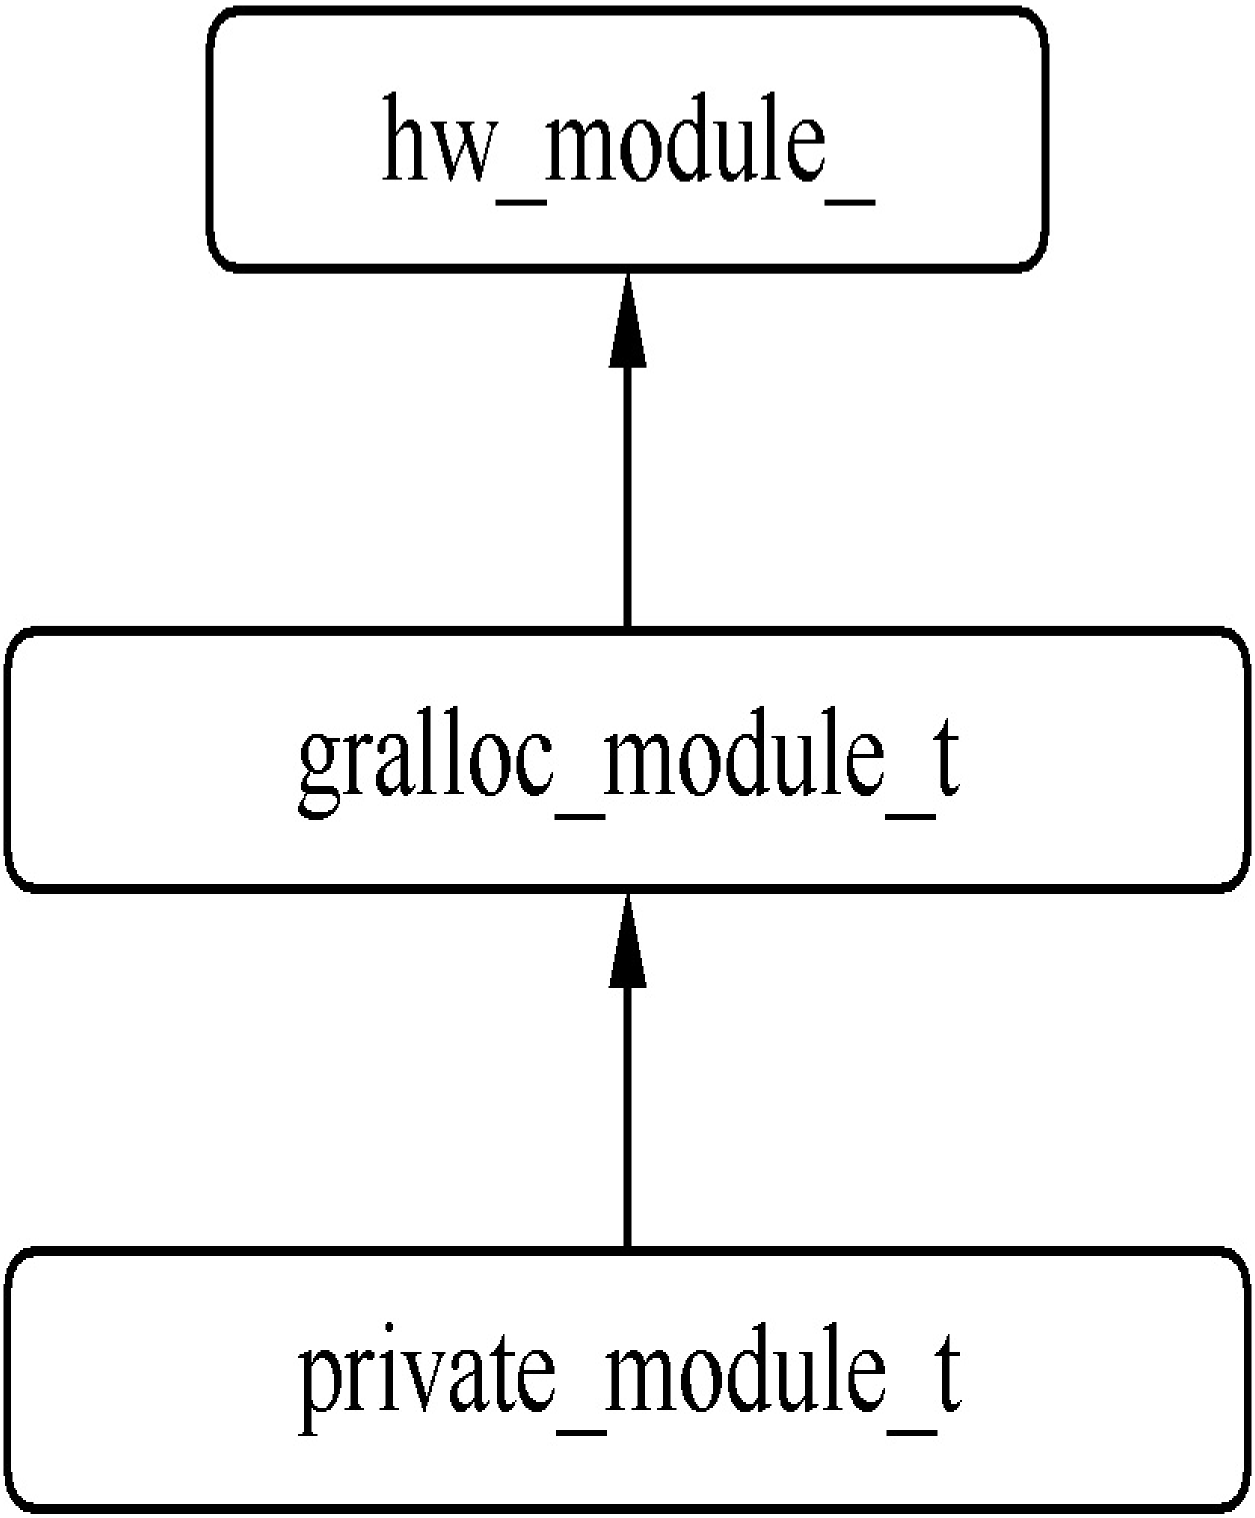

▲图9-5 继承关系

原生态的Gralloc实现中，open方法接口对应的是gralloc_device_open@Gralloc.cpp。这个函数会根据设备名来判断是

打开fb还是gralloc设备。

```
/*hardware/libhardware/modules/gralloc/Gralloc.cpp*/
int gralloc_device_open(const hw_module_t* module, const char* na
{
    int status = -EINVAL;
    if (!strcmp(name, GRALLOC_HARDWARE_GPU0)) {//打开gralloc设备
        …
    } else {
        status = fb_device_open(module, name, device);//否则就是fb
    }
    return status;
}
```

先来大概看看framebuffer设备的打开过程：

```
/*hardware/libhardware/modules/gralloc/Framebuffer.cpp*/
int fb_device_open(hw_module_t const* module, const char* name, h
{
    int status = -EINVAL;
    if (!strcmp(name, GRALLOC_HARDWARE_FB0)) {//设备名是否正确
       fb_context_t *dev = (fb_context_t*)malloc(sizeof(*dev));/分
       这是一个“壳”*/
       memset(dev, 0, sizeof(*dev));//初始化，良好的编程习惯
       …
       dev->device.common.close = fb_close;//这几个接口是fb设备的核心
       dev->device.setSwapInterval = fb_setSwapInterval;
       dev->device.post = fb_post;
       …
       private_module_t* m = (private_module_t*)module;
       status = mapFrameBuffer(m);//内存映射，以及参数配置
       if (status >= 0) {
           …
           *device = &dev->device.common;//“壳”和“核心”的关系
       }
    }
    return status;
}
```

其中fb_context_t是framebuffer内部使用的一个类，它包含了众多信息，而函数参数device的内容只是其内部的device.common。这种“通用和特殊属性”并存的编码风格在HAL库中很常见，大家要习惯。

数据类型fb_context_t里的唯一成员就是framebuffer_device_t，

这是对frambuffer设备的统一描述。一个标准的fb设备通常要提供如下接口实现。

- int (*post)(struct framebuffer_device_t* dev, buffer_handle_t buffer);

　　将buffer数据post到显示屏上。要求buffer必须与屏幕尺寸一致，并且没有被locked。这样buffer内容将在下一次VSYNC中被显示出来。

- int (*setSwapInterval)(struct framebuffer_device_t* window, int interval);

　　设置两个缓冲区交换的时间间隔。

- int (*setUpdateRect)(struct framebuffer_device_t* window, int left, int top, int width, int height);

　　设置刷新区域，需要framebuffer驱动支持“update-on-demand”。也就是说，在这个区域外的数据很可能被认为无效。

　　我们再来解释下framebuffer_device_t中一些重要的成员变量，如表9-1所示。

表9-1　framebuffer_device_t中的重要成员变量

变　　量	
uint32_t　flags	标志位，指示framebuffer的属性配置
uint32_t　width;uint32_t height;	framebuffer的宽和高，以像素为单位
int　　　format	framebuffer的像素格式，比如：HAL_PIXEL_FORMAT_RGBA_8888HAL_PI[illegible]等

loat xdpi;float ydpi;	x和y轴的密度（dot per inch）
float fps	屏幕的每秒刷新频率。假如无法从设备获取讠
int minSwapInterval;int maxSwapInterval;	该framebuffer支持的最小和最大的缓冲交换吋

到目前为止，我们还没看到系统是如何打开Kernel层的fb设备以及如何对fb进行配置的。这些工作都是在mapFrameBuffer()中完成的。这个函数首先尝试打开（调用open接口，权限为O_RDWR）如下路径中的fb设备：

"/dev/graphics/fb%u"或者 "/dev/fb%u"

其中%u当前的实现中只用到了“0”，即当前的系统实现中只会打开一个fb设备（虽然从趋势上看Android是要支持多屏幕显示的）。成功打开fb后，我们可以通过：

```
ioctl(fd, FBIOGET_FSCREENINFO, &finfo);
ioctl(fd, FBIOGET_VSCREENINFO, &info)
```

来得到显示屏的一系列参数，同时通过：

ioctl(fd, FBIOPUT_VSCREENINFO, &info)来对底层fb进行配置。

另外，函数mapFrameBuffer的另一重要任务就是为fb设备做内存映射。主要源码语句如下：

```
void* vaddr = mmap(0, fbSize, PROT_READ|PROT_WRITE, MAP_SHARE
module->framebuffer->base = intptr_t(vaddr);
memset(vaddr, 0, fbSize);
```

由上述代码段可知，映射地址保存在module->framebuffer->base。变量module对应的是前面

hw_get_module(GRALLOC_HARDWARE_MODULE_ID, &module)得到的hw_module_t（被强制类型转化为private_module_t）。

接下来再看看系统打开gralloc设备的过程，它相对于fb简单些。如下所示：

```
/*hardware/libhardware/modules/gralloc/Gralloc.cpp*/
int gralloc_device_open(const hw_module_t* module, const char* na
{
    int status = -EINVAL;
    if (!strcmp(name, GRALLOC_HARDWARE_GPU0)) {
        gralloc_context_t *dev;//做法和fb类似
        dev = (gralloc_context_t*)malloc(sizeof(*dev));//分配空间
        /* initialize our state here */
        memset(dev, 0, sizeof(*dev));
        …
        dev->device.alloc = gralloc_alloc; //从提供的接口来看，grall
        dev->device.free = gralloc_free;
        …
}
```

上述代码段中与fb相似的部分我们就不多做介绍了。因为gralloc担负着图形缓冲区的分配与释放，所以它提供的两个最重要的接口是alloc和free。这里暂时先不深入分析，后续会有讲解。

我们以图9-6来对Gralloc做下小结。

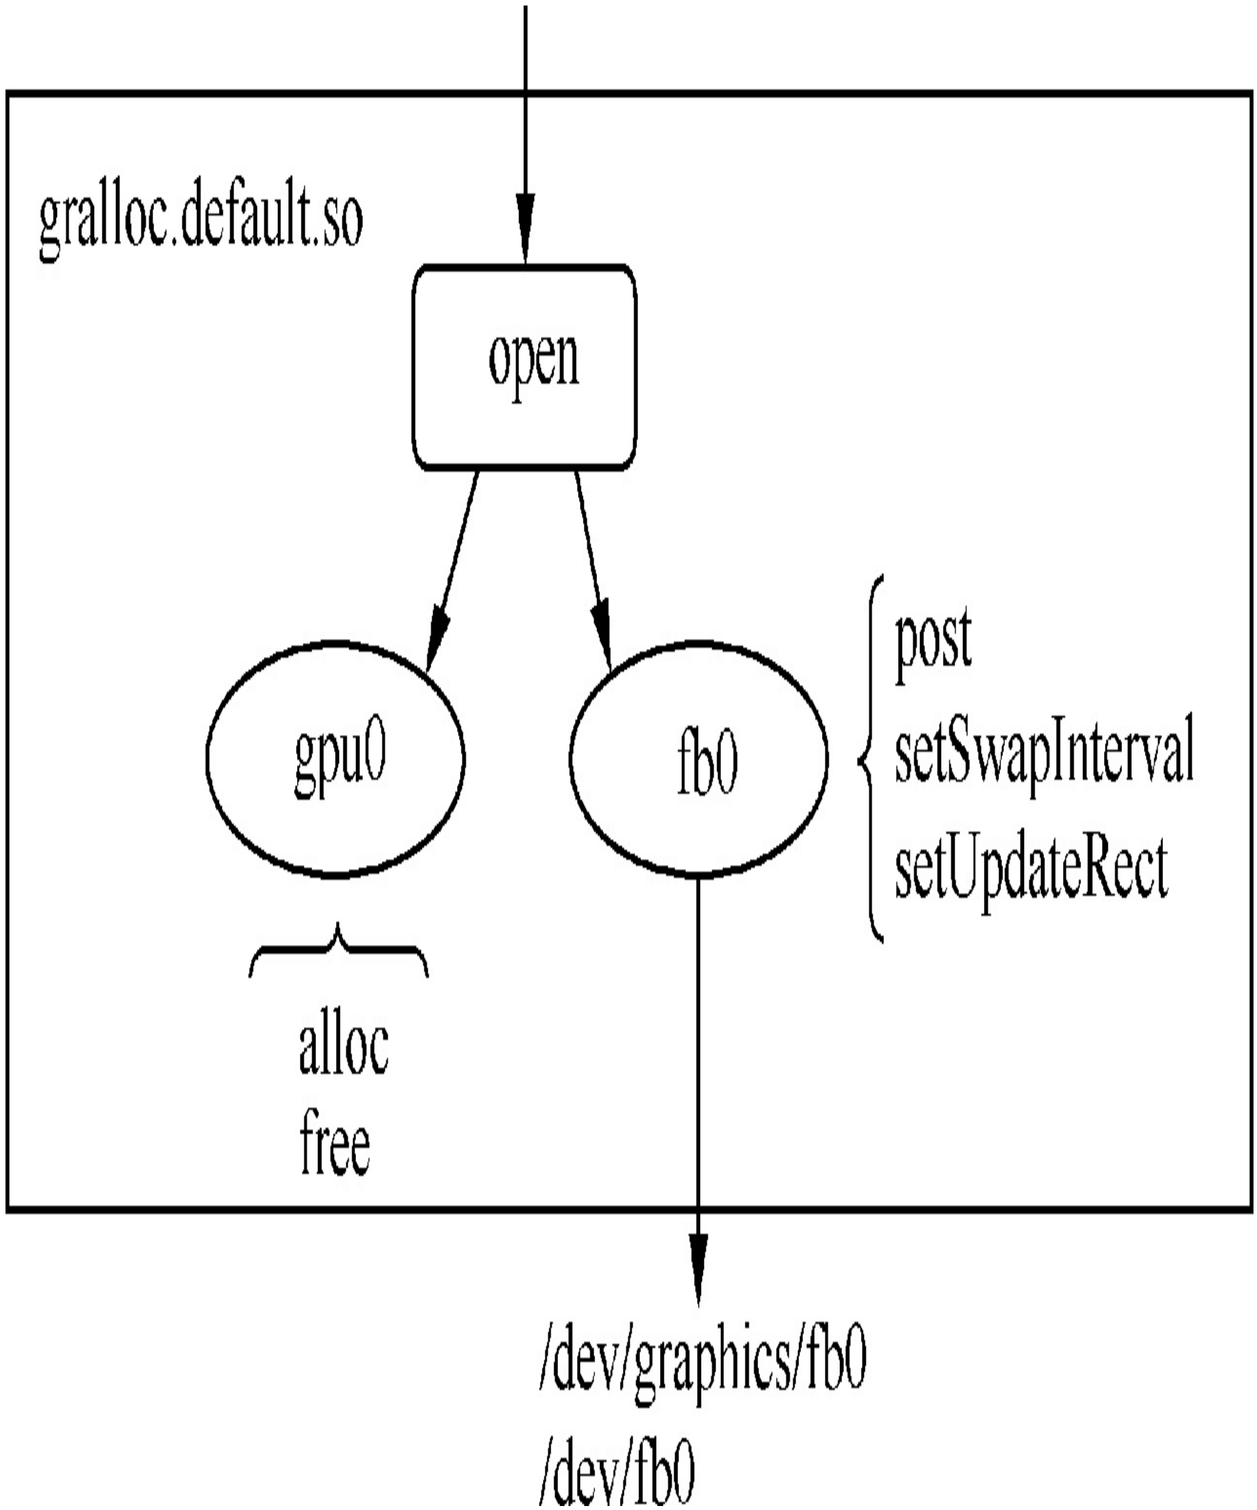

▲图9-6 Gralloc模块简图

9.4 Android中的本地窗口

在OpenGL的学习过程中，我们不断提及“本地窗口”（Native Window）这一概念。简单而言，Native Window为OpenGL与本地窗口系统之间搭建了“桥梁”，所以成为OpenGL能否兼容多种系统（如Windows，Android）的关键。那么对于Android系统来说，它是如何将OpenGL ES本地化的呢？或者说，它提供了什么样的本地窗口？

根据整个Android系统的GUI设计理念，我们不难猜想到至少需要两种本地窗口。

- 面向管理者（SurfaceFlinger）

既然SurfaceFlinger扮演了系统中所有UI界面的管理者，那么它无可厚非需要直接或间接地持有“本地窗口”。我们知道，这个窗口就是FramebufferNativeWindow。

- 面向应用程序

这类本地窗口是Surface。

可能有的读者会感到困惑，一个系统设计一种本地窗口不就可以了吗？为什么需要两个甚至更多呢？理论上我们的确可以只

通过一个本地窗口来实现，如图9-7所示。

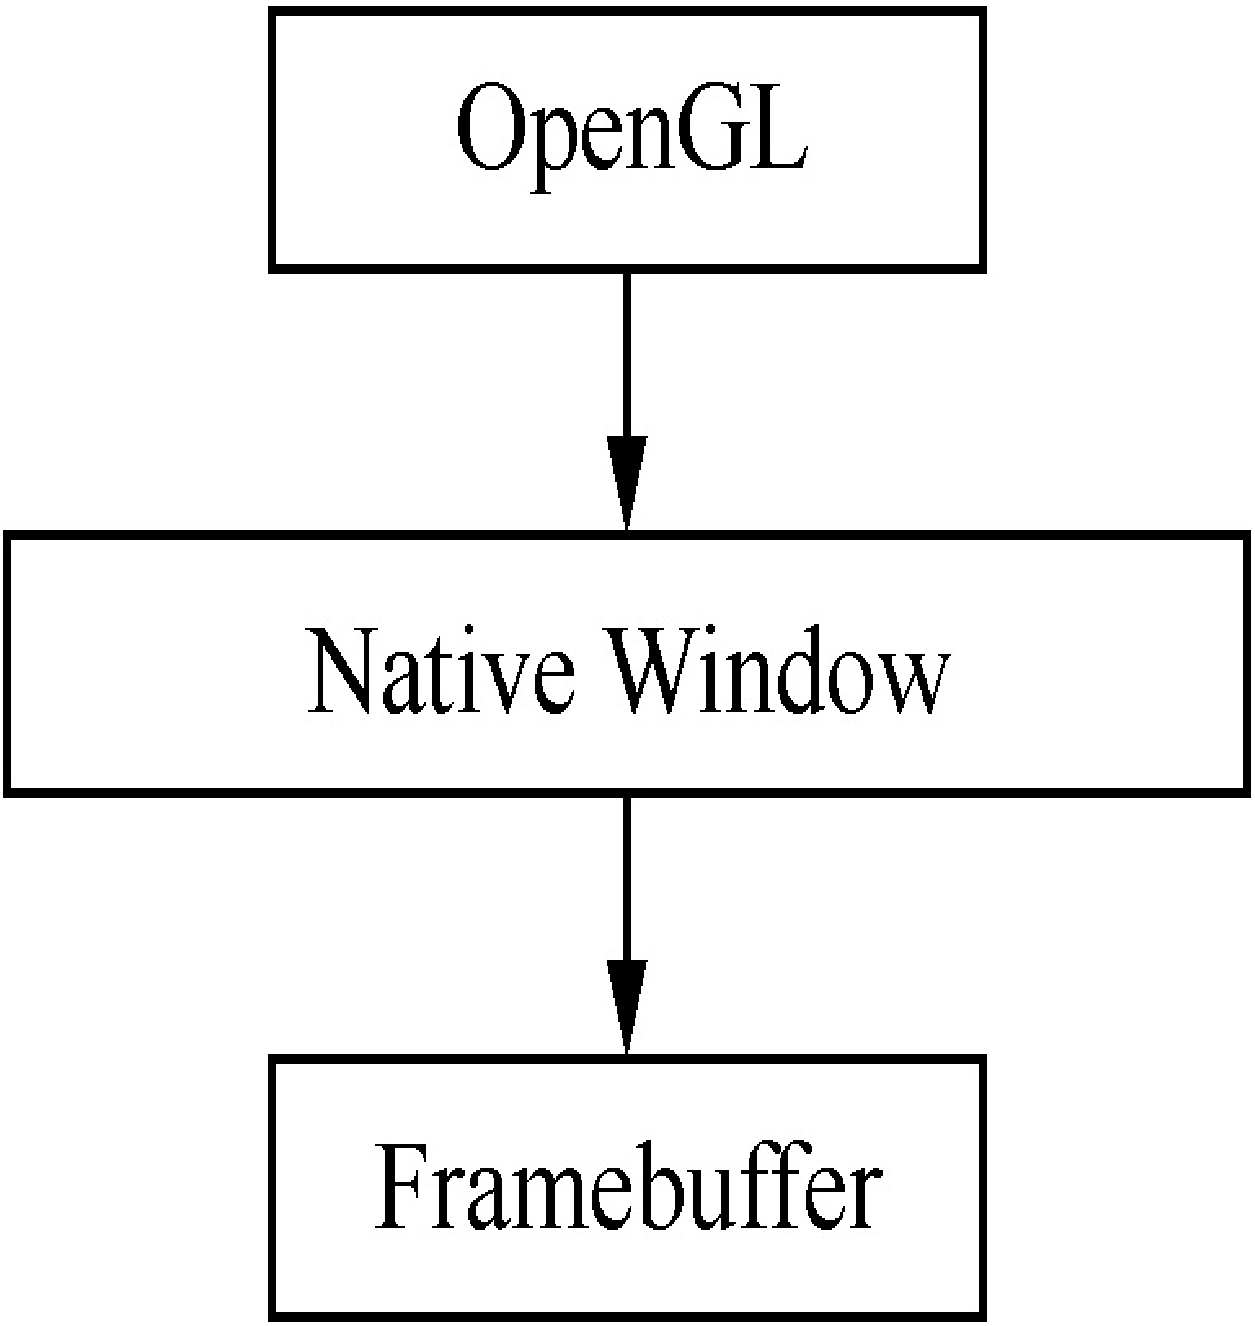

▲图9-7 理想的窗口系统

上面这个窗口系统中，由Native Window来管理Framebuffer。打个比方，OpenGL就像一台通用的打印机一样，只要输入正确的指令，就能按照要求输出结果；而Native Window则是“纸”，它是用来承载OpenGL的输出结果的。OpenGL并不介意Native Window是A4或者A6纸，甚至是塑料纸也没有关系，这些对它来说都只是“本地窗口”。

我们再来思考下，这种理想模型能否符合Android的要求。假如整个系统仅有一个需要显示UI的程序，我们有理由相信它可以胜任。但是如果有N个UI程序的情况会怎样呢？

一个系统设备中显然只会有一个帧缓冲区Framebuffer，而按照“理想窗口系统”的设计，每个应用程序都需要各自使用和管理Framebuffer ——其结果就会像“幼儿园”的几个小朋友共用一块画板来涂鸦一样，可谓“五彩斑斓”“创意无限”。

那么该如何改进呢？如图9-8所示。

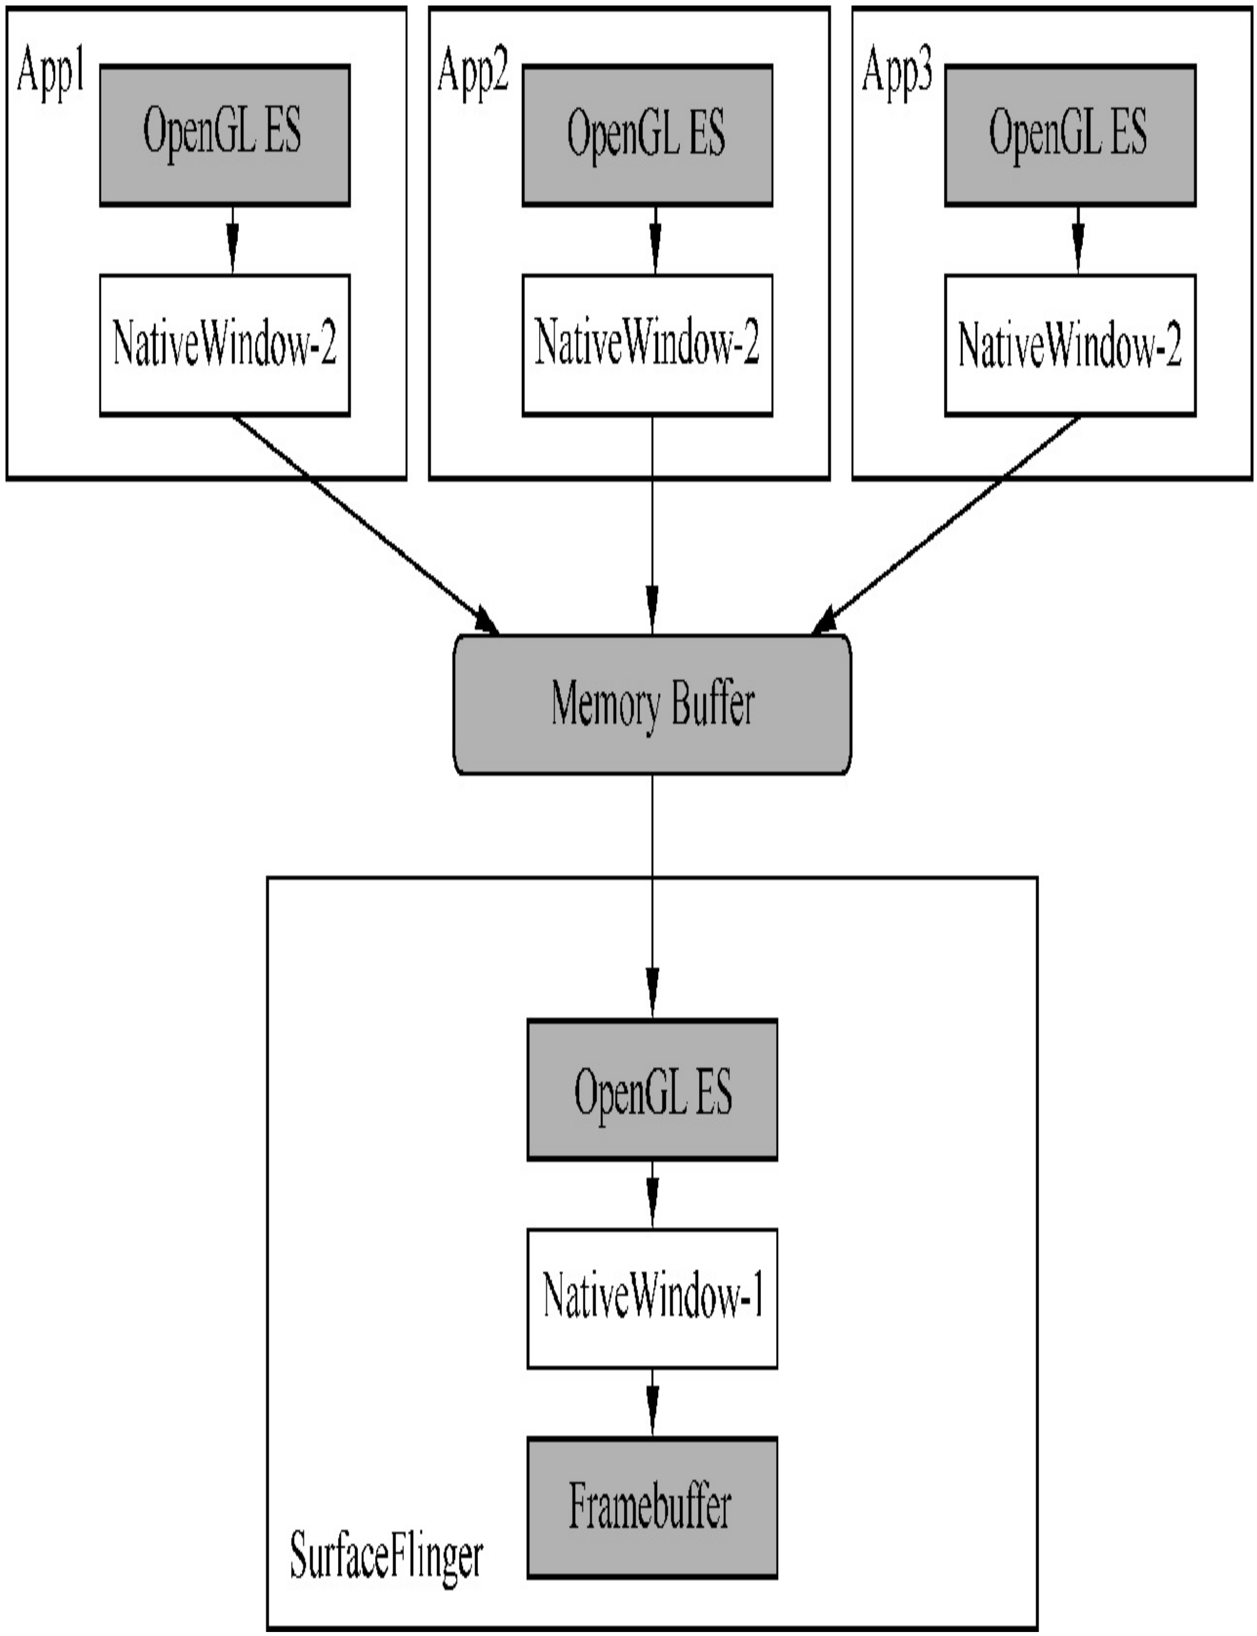
App1
OpenGL ES
NativeWindow-2
App2
OpenGL ES
NativeWindow-2
App3
OpenGL ES
NativeWindow-2
Memory Buffer
OpenGL ES
NativeWindow-1
Framebuffer
SurfaceFlinger

▲图9-8　改进的窗口系统

在这个改进的窗口系统中，我们有了两类本地窗口，即NativeWindow-1和NativeWindow-2。第一类窗口是能直接显示在终端屏幕上的——它使用了帧缓冲区；而后一类本地窗口实际上是从内存缓冲区中分配的空间。

当系统中存在多个需要显示UI的应用程序时，一方面这种改进设计保证了它们都能获得一个“本地窗口”；另一方面这些“本地窗口”也都可以被有序地显示到终端屏幕上——因为SurfaceFlinger会收集所有程序的显示需求，对它们进行统一的图像混合操作，然后输出到自己的NativeWindow-1上。

当然，这个改进的窗口系统有一个前提，即应用程序与SurfaceFlinger都是基于OpenGL ES来实现的。有没有其他选择呢？答案是肯定的。比如应用程序完全可以采用Skia等第三方的图形库，只要它们与SurfaceFlinger间的“协议”保持不变即可，如图9-9所示。

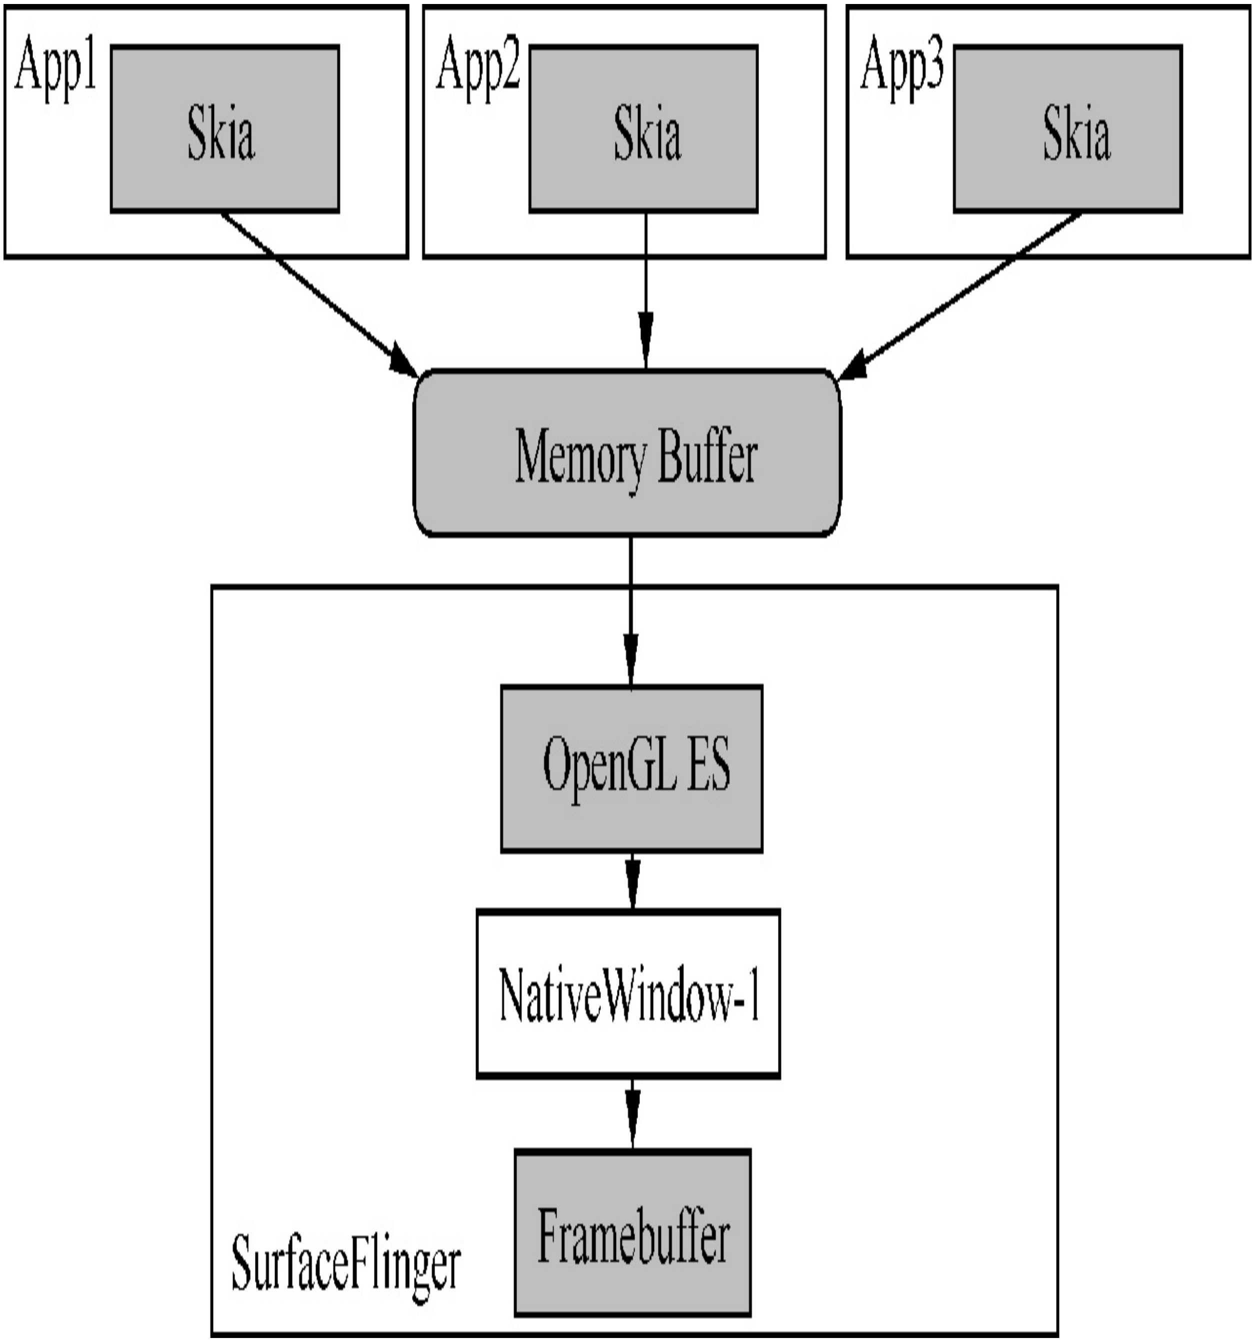

▲图9-9　另一类改进的窗口系统

从理论上来说，上述两类改进的窗口系统都是可行的。不过对于开发人员，特别是没有OpenGL ES项目经验的人而言，前一类改进方案的门槛相对较高。而事实上，Android系统同时提供了这两种方案来供上层选择。正常情况下我们按照SDK向导生成的APK应用程序，属于后面的情况；而对于希望使用OpenGL ES来完成复杂界面渲染的应用开发者来

说，也可以使用Android系统封装的GLSurfaceView（或其他方式）来达到目标。

在接下来的源码分析中，我们将对本小节提及的“改进系统”做进一步验证。

9.4.1 FramebufferNativeWindow

我们知道，EGL需要通过本地窗口来为OpenGL/OpenGL ES创造环境。其函数原型如下：

```
EGLSurface eglCreateWindowSurface(  EGLDisplay dpy, EGLConfig con
NativeWindowTypewindow, const EGLint *attrib_list);
```

显然不论是哪一类本地窗口，都必须要与NativeWindowType保持一致，否则就无法正常使用EGL了。先从数据类型的定义来看看这个window参数有什么特别之处：

```
/*frameworks/native/opengl/include/egl/Eglplatform.h*/
typedef EGLNativeWindowType  NativeWindowType;//注意这两种数据类型其
…
#if defined(_WIN32) || defined(__VC32__) && !defined(__CYGWIN__)
 /* Win32 和 WinCE系统下的定义 */
…
typedef HWND    EGLNativeWindowType;
#elif defined(__WINSCW__) || defined(__SYMBIAN32__)  /* Symbian系
…
typedef void *EGLNativeWindowType;
#elif defined(__ANDROID__) || defined(ANDROID)/* Android系统 */
struct ANativeWindow;
…
typedef struct ANativeWindow* EGLNativeWindowType;
…
#elif defined(__unix__)/* UNIX系统 */
…
typedef Window   EGLNativeWindowType;
#else
#error "Platform not recognized"
#endif
```

我们以表9-2来概括在不同的操作系统平台下EGLNativeWindowType所对应的具体数据类型。

表9-2　不同操作系统平台下的EGLNativeWindowType

操 作 系 统	数 据 类 型
Win32, WinCE	HWND，即句柄
Symbian	Void*
Android	ANativeWindow*
UNIX	Window
其他	暂时不支持

由于OpenGL ES并不是只针对某一个特定的操作系统平台设计的，因而需要考虑兼容性和可移植性。这个EGLNativeWindowType就是一个例子，它在不同的系统中对应的是不同的数据类型，如Android中就指的是ANativeWindow指针。

ANativeWindow的定义在Window.h头文件中：

```
/*system/core/include/system/Window.h*/
struct ANativeWindow
{…
    const uint32_t flags; //与Surface或updater有关的属性
    const int   minSwapInterval;//所支持的最小交换间隔时间
    const int   maxSwapInterval;//所支持的最大交换间隔时间
    const float xdpi; //水平方向的密度，以dpi为单位
    const float ydpi;//垂直方向的密度，以dpi为单位
    intptr_t    oem[4];//为OEM定制驱动所保留的空间
    int (*setSwapInterval)(struct ANativeWindow* window, int inte
    int (*dequeueBuffer)(struct ANativeWindow* window,
                struct ANativeWindowBuffer** buffer, int* fenceFd
    int (*queueBuffer)(struct ANativeWindow* window,
```

```
                struct ANativeWindowBuffer* buffer, int fenceFd);
    int (*cancelBuffer)(struct ANativeWindow* window,
                struct ANativeWindowBuffer* buffer, int fenceFd);
    int (*query)(const struct ANativeWindow* window,int what, int
    int (*perform)(struct ANativeWindow* window,int operation, ..
    void* reserved_proc[2];
};
```

我们在表9-3中详细解释ANativeWindow这个数据结构中的几个重要成员函数。

表9-3　ANativeWindow成员函数解析

Member Function	
setSwapInterval	设置交换间隔时间，后面会讲解swap的作用
dequeueBuffer	EGL通过这个接口来申请一个buffer。从前面我们所举的 含的buffer很可能不止一份
queueBuffer	当EGL对一块buffer渲染完成后，它调用这个接口来unlo
cancelBuffer	这个接口可以用来取消一个已经dequeued的buffer，但要
query	用于向本地窗口咨询相关信息
perform	用于执行本地窗口支持的各种操作，比如： NATIVE_WINDOW_SET_USAGENATIVE_WINDOW_S 等

从上面对ANativeWindow的描述可以看出，它更像一份“协议”，

规定了一个本地窗口的形态和功能。这对于支持多种本地窗口的系统是必需的，因为只有这样我们才能针对某种特定的平台窗口来填充具体的实现。

这个小节中我们需要分析FramebufferNativeWindow是如何履行这份“协议”的。

FramebufferNativeWindow本身代码并不多，下面分别选取其构造函数及dequeue函数来分析。其他部分的实现都类似，大家可以参考阅读。

1．FramebufferNativeWindow构造函数

根据FramebufferNativeWindow所完成的功能，可以大概推测出它的构造函数里应该至少完成如下初始化操作。

- 加载GRALLOC_HARDWARE_MODULE_ID模块，详细流程在Gralloc小节已经解释过了。

- 分别打开fb和gralloc设备。我们在Gralloc小节也已经分析过，打开后的设备由全局变量fbDev和grDev管理。

- 根据设备的属性来给FramebufferNativeWindow赋初值。

- 根据FramebufferNativeWindow的实现来填充ANativeWindow中的“协议”。

- 其他一些必要的初始化。

下面从源码的角度来分析上述每个步骤具体是怎么实现的：

```
/*frameworks/native/libs/ui/FramebufferNativeWindow.cpp*/
FramebufferNativeWindow::FramebufferNativeWindow()
    : BASE(), fbDev(0), grDev(0), mUpdateOnDemand(false)
{
    hw_module_t const* module;
    if (hw_get_module(GRALLOC_HARDWARE_MODULE_ID, &module) == 0)
        int stride;
        int err;
        int i;
```

```
        err = framebuffer_open(module, &fbDev);
        err = gralloc_open(module, &grDev);//分别打开fb和gralloc
        /*上面这部分内容我们在前几个小节已经分析过了，不清楚的可以回头看一下
        …
        if(fbDev->numFramebuffers >= MIN_NUM_FRAME_BUFFERS &&
           fbDev->numFramebuffers <= MAX_NUM_FRAME_BUFFERS){//根据
            mNumBuffers = fbDev->numFramebuffers;
        } else {
            mNumBuffers = MIN_NUM_FRAME_BUFFERS;//否则就采用最少的bu
        }
        mNumFreeBuffers = mNumBuffers;//可用的buffer个数，初始时是所
        mBufferHead = mNumBuffers-1;
        …
        for (i = 0; i < mNumBuffers; i++) //给每个buffer初始化
        {
            buffers[i] = new NativeBuffer(fbDev->width, fbDev->he
                                  GRALLOC_USAGE _HW_FB);
        }//NativeBuffer是什么？

        for (i = 0; i < mNumBuffers; i++) //给每个buffer分配空间
        {
            err = grDev->alloc(grDev, fbDev->width, fbDev->height
                       GRALLOC_USAGE_HW_FB, &buffers[i]->handle, 
            …
        }
             /*为本地窗口赋属性值*/
        const_cast<uint32_t&>(ANativeWindow::flags) = fbDev->flag
        const_cast<float&>(ANativeWindow::xdpi) = fbDev->xdpi;
        const_cast<float&>(ANativeWindow::ydpi) = fbDev->ydpi;
        const_cast<int&>(ANativeWindow::minSwapInterval) =fbDev->
        const_cast<int&>(ANativeWindow::maxSwapInterval) = fbDev-
    } else {
        ALOGE("Couldn't get gralloc module");
    }
    /*以下代码段开始履行窗口“协议”*/
    ANativeWindow::setSwapInterval = setSwapInterval;
    ANativeWindow::dequeueBuffer = dequeueBuffer;
    ANativeWindow::queueBuffer = queueBuffer;
    ANativeWindow::query = query;
    ANativeWindow::perform = perform;
    /*下面这几个接口已经被废弃了，不过为了保持兼容性，暂时还是保留的*/
    ANativeWindow::dequeueBuffer_DEPRECATED = dequeueBuffer_DEPRE
    ANativeWindow::lockBuffer_DEPRECATED = lockBuffer_DEPRECATED;
    ANativeWindow::queueBuffer_DEPRECATED = queueBuffer_DEPRECATE
}
```

这个函数逻辑上很简单，开头一部分我们已经分析过，此处不再赘

述。需要重点关注的是FramebufferNativeWindow是如何分配buffer的。换句话说，其dequeue方法所获得的缓冲区是从何而来的。

成员变量mNumBuffers代表了FramebufferNativeWindow所管理的buffer总数。它取决于两个方面：首先从fb设备中取值，即numFramebuffers；否则就默认定义为MIN_NUM_FRAME_BUFFERS。如下所示：

```
#define MIN_NUM_FRAME_BUFFERS  2
#define MAX_NUM_FRAME_BUFFERS  3
```

可见Android系统认为最少的buffer数为2，最大为3。

有人可能会觉得奇怪，既然FramebufferNativeWindow对应的是真实的物理屏幕，那么为什么还需要两个buffer呢？

假设我们需要绘制这样一个UI画面，包括两个三角形和3个圆形，如图9-10所示。

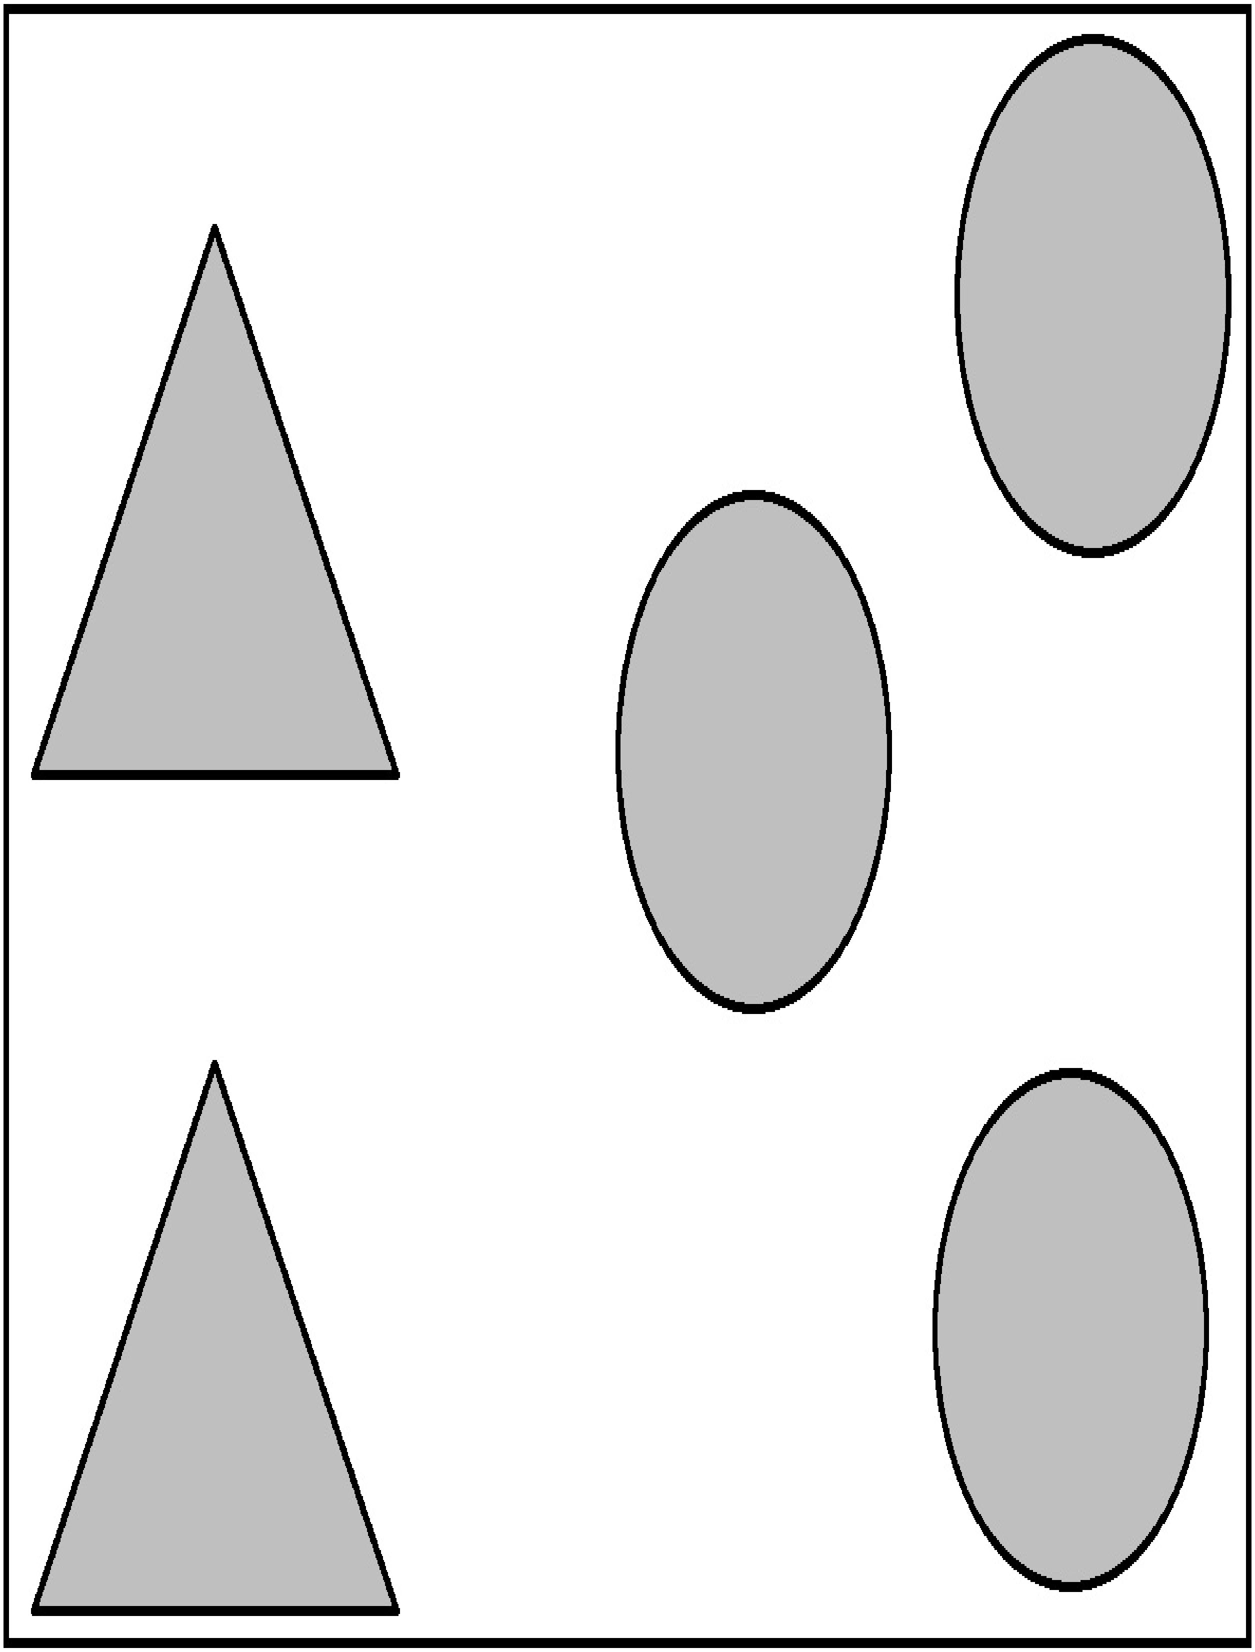

▲图9-10 希望在屏幕上显示的完整结果

接下来大家可以思考下只采用一个buffer时的情况。这意味着我们是直接以屏幕为画板来实时做画——我们画什么，屏幕上就显示什么。以图9-10为例，如果每一个三角形或圆形都需要0.5s的绘图时间，那么总计耗时应该是0.5*5=2.5s。换句话说，不同时间点时用户在屏幕上所看到的画面如图9-11所示。

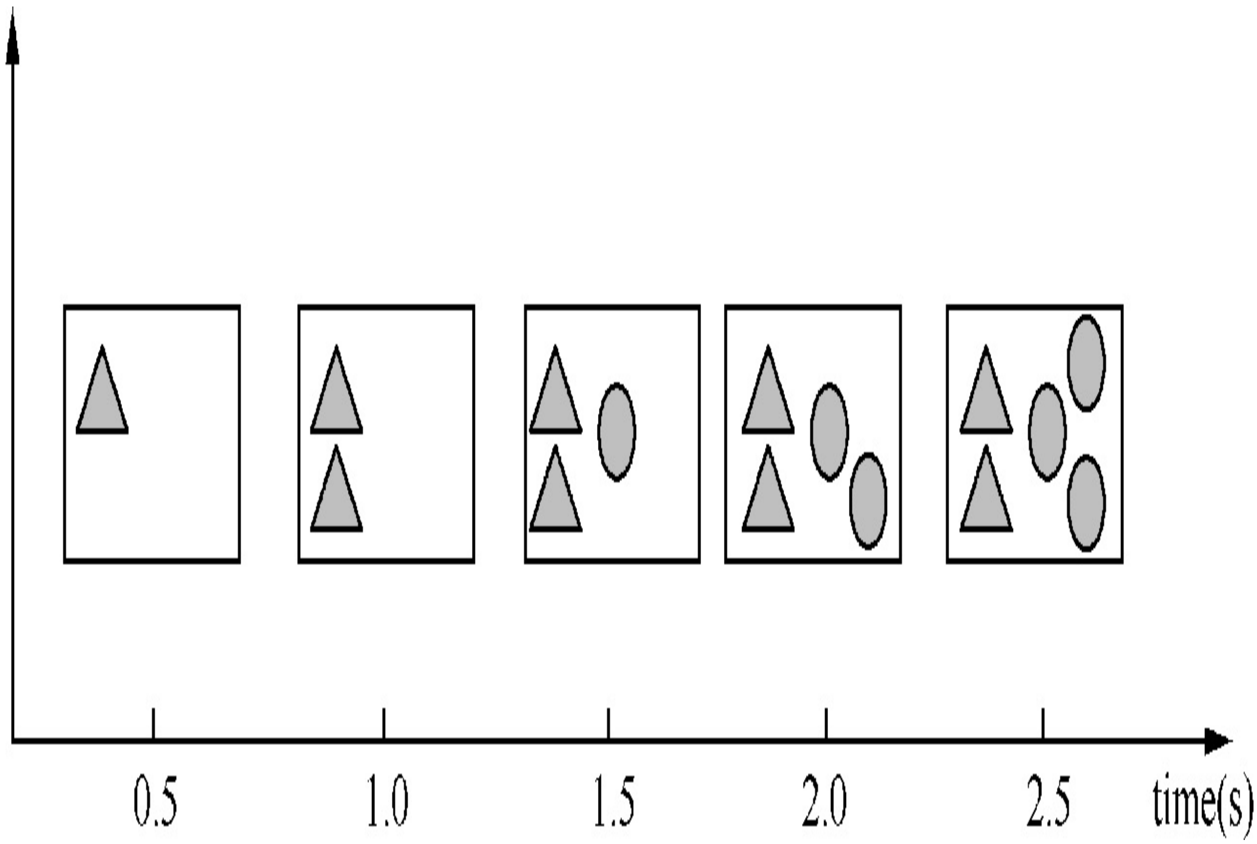

▲图9-11　只采用一个buffer的情况

对于用户来说，将看到一个不断刷新的画面。通俗地讲，就是画面很“卡”。特别是对于图像刷新很频繁的场景（比如大型游戏），用户的体验就会更差。那么，有什么解决的办法呢？我们知道，出现这种现象的原因就是程序直接以屏幕为绘图板，把还没有准备就绪的图像直接呈现给了用户。换句话说，如果可以等到整幅图像绘制完成以后再刷新到屏幕上，那么用户在任何时候看到的都是正确而完整的画面，问题也就解决了。图9-12解释了采用两个缓冲区时的情况。

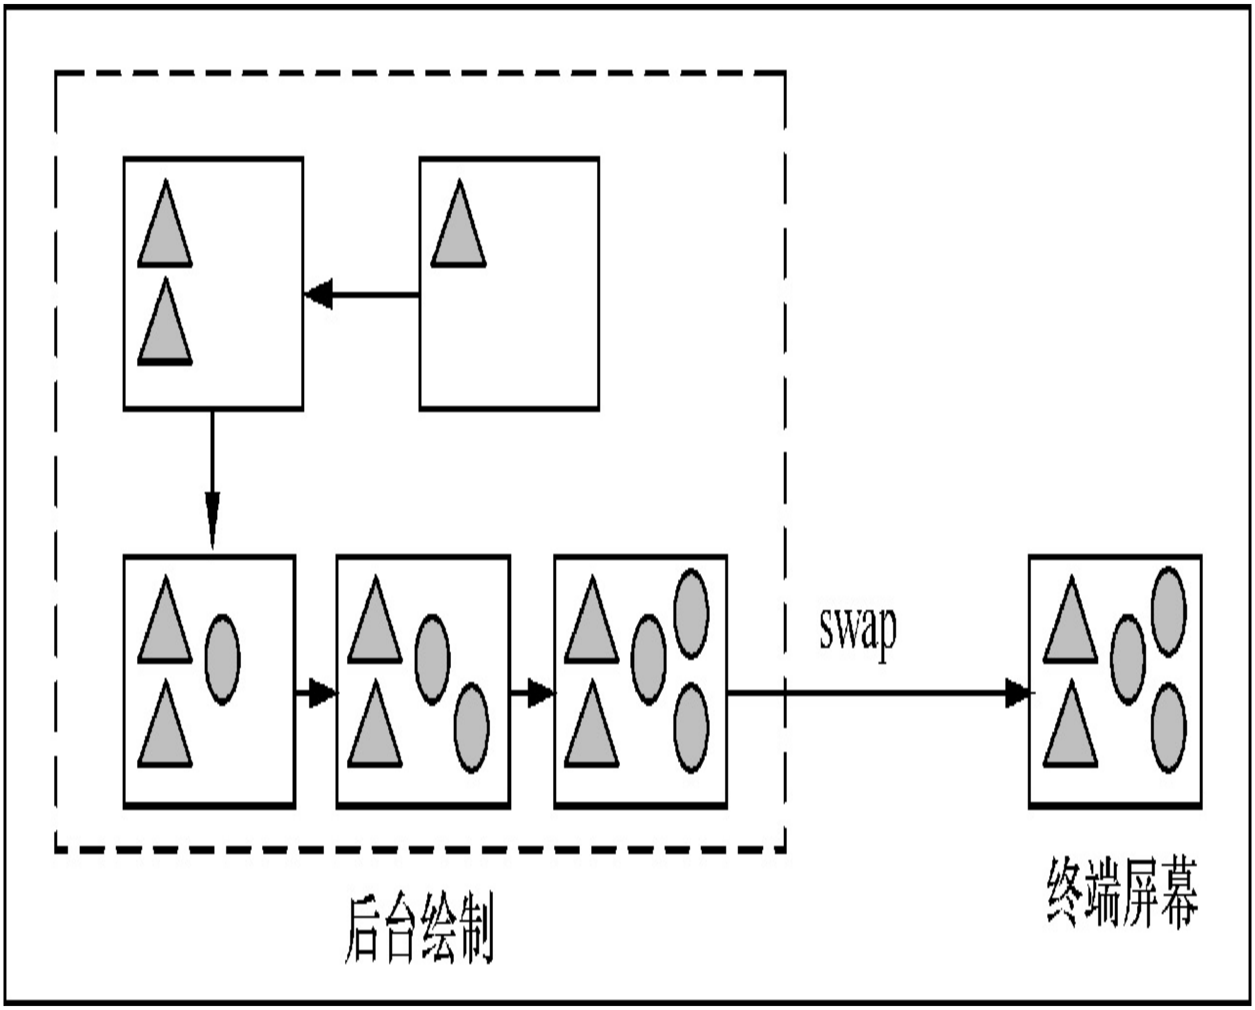

▲图9-12　采用两个缓冲区的情况

图9-12中所阐述的就是通常所称的“双缓冲”（Double-Buffering）技术。除此之外，其实还有三缓冲（Triple Buffering）、四缓冲（Quad Buffering）等，我们将它们统称为“多缓冲”（Multiple Buffering）机制。

理解了为什么需要双缓冲以后，我们再回过头来看FramebufferNativeWindow的构造函数。接下来要解决的另一个问题是：多个缓冲区空间是从哪里分配的？通过前几个小节的知识可知，应该是要向HAL层的Gralloc申请。

FramebufferNativeWindow构造函数中的第一个for循环里先给各buffer创建相应的实例（new NativeBuffer），其中的属性值都来源于fbDev，如宽、高、格式等。紧随其后的就是调用Gralloc设备的

alloc()方法：

```
err = grDev->alloc(grDev, fbDev->width, fbDev->height, fbDev->for
GRALLOC_USAGE_HW_FB, &buffers[i]->handle, &buffers[i]->stride);
```

注意第5个参数，它代表所要申请的缓冲区的用途，定义在hardware/libhardware/include/ hardware/Gralloc.h中，目前已经支持几十种。比如：

- GRALLOC_USAGE_HW_TEXTURE

  缓冲区将用于OpenGL ES Texture。

- GRALLOC_USAGE_HW_RENDER

  缓冲区将用于OpenGL ES的渲染。

- GRALLOC_USAGE_HW_2D

  缓冲区会提供给2D 硬件图形设备。

- GRALLOC_USAGE_HW_COMPOSER

  缓冲区用于HWComposer HAL模块。

- GRALLOC_USAGE_HW_FB

  缓冲区用于framebuffer设备。

- GRALLOC_USAGE_HW_VIDEO_ENCODER

  缓冲区用于硬件视频编码器。

  ……

这里申请的缓冲区是要在终端屏幕上显示的，所以申请的usage类型是GRALLOC_USAGE_HW_FB，对应的Gralloc中的实现是gralloc_alloc_framebuffer@Gralloc.cpp；假如是其他用途的缓冲区申请，则对应gralloc_alloc_buffer@Gralloc.cpp。不过，如果底层只

允许一个buffer（不支持page-flipping的情况），那么gralloc_alloc_framebuffer也同样可能只返回一个ashmem中申请的“内存空间”，真正的“帧缓冲区”则要在post时才会被用到。

所有申请到的缓冲区都需要由FramebufferNativeWindow中的全局变量buffers[MAX_NUM_FRAME_BUFFERS]来记录，每个数据元素是一个NativeBuffer。这个类的定义如下：

```
class NativeBuffer : public ANativeObjectBase<ANativeWindowBuffer
       NativeBuffer,LightRefBase<NativeBuffer>>
{…
```

可见这个“本地缓冲区”继承了ANativeWindowBuffer的特性，后者的定义在/system/core/ include/system/Window.h中：

```
typedef struct ANativeWindowBuffer
{…
    int width; //宽
    int height;//高
    …
    buffer_handle_t handle;/*代表内存块的句柄，比如ashmem机制。可以参考
    …
} ANativeWindowBuffer_t;
```

另外，当前可用（free）的buffer数量由mNumFreeBuffers管理，这个变量的初始值也是mNumBuffers，即总共有2或3个可用缓冲区。在程序后续的运行过程中，始终由mBufferHead来指向下一个将被申请的buffer（注意：不是下一个可用buffer）。也就是说，每当用户向FramebufferNativeWindow申请一个buffer时（dequeueBuffer），这个mBufferHead就会增加1；一旦它的值超过最大值，则还会变成0，如此就实现了循环管理。后面在讲解dequeueBuffer时再详细解释。

一个本地窗口包含了很多属性值，如各种标志（flags）、横纵坐标的密度值等。这些数值都可以从fb设备中查询到，我们需要将它们赋予刚生成的FramebufferNativeWindow实例的属性。

最后，就应该履行ANativeWindow的接口协议了。FramebufferNativeWindow会将其对应的成员函数逐个填充到ANativeWindow的函数指针中。比如：

```
ANativeWindow::setSwapInterval = setSwapInterval;
```

```
ANativeWindow::dequeueBuffer = dequeueBuffer;
```

……

这样子OpenGL ES才能通过一个ANativeWindow来与本地窗口系统建立正确的连接。下面我们详细分析其中dequeueBuffer的实现。

2．dequeueBuffer

这个函数虽然很短（只有二十几行），却是FramebufferNativeWindow中的核心。OpenGL ES就是通过它来分配一个可用于渲染的缓冲区的：

```
int FramebufferNativeWindow::dequeueBuffer(ANativeWindow* window,
{
    FramebufferNativeWindow* self = getSelf(window); /*Step1*/
    Mutex::Autolock _l(self->mutex);/*Step2*/
    …
    /*Step3. 计算mBufferHead */
    int index = self->mBufferHead++;
    if (self->mBufferHead >= self->mNumBuffers)
        self->mBufferHead = 0;//循环

    /*Step4. 如果当前没有可用缓冲区*/
    while (!self->mNumFreeBuffers) {
        self->mCondition.wait(self->mutex);
    }
    /*Step5. 如果有人释放了缓冲区*/
    self->mNumFreeBuffers--;
    self->mCurrentBufferIndex = index;
    *buffer = self->buffers[index].get();
    *fenceFd = -1;
    return 0;
}
```

Step1@FramebufferNativeWindow::dequeueBuffer，这里先将入参中ANativeWindow类型的变量window强制转化为FramebufferNativeWindow。因为前者是后者的父类，所以这样的转化当然是有效的。不过细心的读者可能会发现，为什么函数入参中还要特别传入一个ANativeWindow对象的内存地址，直接使用FramebufferNativeWindow的this指针不行吗？这么做很可能是为了兼容各种平台。大家应该注意到ANativeWindow是一个Struct数据类型，而在C语言中Struct是没有成员函数的，所以我们通常是用函数指针的

形式来模拟一个成员函数，如这个dequeueBuffer在ANativeWindow的定义就是一个函数指针，而且系统并没有办法预先知道最终填充到ANativeWindow中的函数指针实现（如FramebufferNativeWindow::dequeueBuffer）里是否可以使用this指针，所以在参数中带入一个window变量就是必要的。

Step2@ FramebufferNativeWindow::dequeueBuffer，获得一个Mutex锁。因为接下来的操作涉及资源互斥区，自然需要有一个保护措施。这里采用的是Autolock，意味着dequeueBuffer函数结束后会自动释放Mutex。

Step3@ FramebufferNativeWindow::dequeueBuffer，前面我们介绍过mBufferHead变量，这里来看看它的实际使用。首先index得到的是mBufferHead所代表的当前位置，然后mBufferHead增加1。由于我们是循环利用多个缓冲区的，所以如果这个变量的值大于或等于mNumBuffers，那么就需要把它置为0。也就是说，mBufferHead的值永远只能是[0-2]中的一个。

Step4@ FramebufferNativeWindow::dequeueBuffer，mBufferHead并不代表它所指向的缓冲区是可用的。假如当前的mNumFreeBuffers表明已经没有多余的缓冲区空间，那么我们就需要等待有人释放buffer后才能继续操作。这里使用到Condition这一同步机制，如果读者感觉不熟悉请参考本书进程章节的详细描述。可以肯定的是，这里调用了mCondition.wait，那么必然有其他地方要唤醒它——具体的就是在queueBuffer()中，大家可以验证下是否如此。

Step5@ FramebufferNativeWindow::dequeueBuffer，一旦成功获取到一个buffer后，程序要把可用的buffer计数值减1（mNumFreeBuffers--）。另外mBufferHead前面已经做过自增（++）处理，这里就不用再做特别工作。

这样我们就完成了Android系统中FramebufferNativeWindow本地窗口的分析。接下来的小节将继续讲解另一个重要的Native Window。

9.4.2　应用程序端的本地窗口——Surface

针对应用程序端的本地窗口是Surface，和FramebufferNativeWindow一样，它必须继承AnativeWindow：

```
class Surface
    : public ANativeObjectBase<ANativeWindow, Surface, RefBase>
```

这个本地窗口当然也需要实现ANativeWindow所制定的“协议”，我们关注的重点是它与前面的FramebufferNativeWindow有什么不同。Surface的构造函数只是简单地给ANative Window::dequeueBuffer等函数指针及内部变量赋了初值。由于整个函数的功能很简单，我们只摘录部分核心内容：

```
/*frameworks/native/libs/gui/Surface.cpp*/
Surface::Surface(const sp<IGraphicBufferProducer>& bufferProducer
{/*给ANativeWindow中的函数指针赋值*/
    ANativeWindow::setSwapInterval  = hook_setSwapInterval;
    ANativeWindow::dequeueBuffer    = hook_dequeueBuffer;
    …
    /*为各内部变量赋值，因为此时用户还没有发起申请，所以大部分变量的初始值是0
    mReqWidth = 0;
    mReqHeight = 0;
    …
    mDefaultWidth = 0;
    mDefaultHeight = 0;
    mUserWidth = 0;
    mUserHeight = 0;…
}
```

Surface是面向Android系统中所有UI应用程序的，即它承担着应用进程中的UI显示需求。基于这点，可以推测出其内部实现至少要考虑以下几点。

- 面向上层实现（主要是Java层）提供绘制图像的“画板”

前面说过，这个本地窗口分配的内存空间不属于帧缓冲区，那么具体是由谁来分配的，又是如何管理的呢？

- 它与SurfaceFlinger间是如何分工的

显然SurfaceFlinger需要收集系统中所有应用程序绘制的图像数据，然后集中显示到物理屏幕上。在这个过程中，Surface扮演了什么样的角色呢？

我们先来解释下这个类中一些重要的成员变量，如表9-4所示。

表9-4　　Surface部分成员变量一览

成员变量	说　　明
sp<IGraphicBufferProducer> mGraphicBufferProducer	这个变量是Surface的核心，很多“协议”就是通过它实现的，后面会有详细讲解。值得一提的是，它已经多次改名，4.1的版本中叫作mSurfaceTexture，后更名为mBufferProducer，而目前最新版本则是mGraphicBufferProducer。从中也可以看出，Google开发人员希望为它取一个更容易理解的名称。“Producer”很好地解释了这个变量的作用
BufferSlot mSlots[NUM_BUFFER_SLOTS]	从名称上不难看出，这是Surface内部用于存储buffer的地方，容量NUM_BUFFER_SLOTS最多可达32个。BufferSlot类的内部又由一个GraphicBuffer和一个dirtyRegion组成，当用户dequeueBuffer时才会分配真正的空间
uint32_t mReqWidth	Surface中有多组相似的宽/高变量，它们之间是有区别的。这里的宽和高是指下一次dequeue时将会申请的尺寸，初始值都是1

uint32_t mReqHeight	
uint32_t mReqFormat	和上面两个变量类似，这是指下次dequeue时将会申请的buffer的像素格式，初始值是PIXEL_FORMAT_RGBA_8888
uint32_t mReqUsage	指下次dequeue时将会指定的usage类型
Rect mCrop	Crop表示“修剪”，这个变量将在下次queue时用于修剪缓冲区，可以调用setCrop来设置具体的值
int mScalingMode	同样，这个变量将用于下次queue时对缓冲区进行scale，可以调用setScalingMode来设置具体的值
uint32_t mTransform	用于下次queue时的图形翻转等操作（Transform）
uint32_t mDefaultWidth	默认情况下的缓冲区宽高值
uint32_t mDefaultHeight	
	如果不为零的话，就是应用层指定的值，而且会覆盖前面的

uint32_t mUserWidth	mDefaultWidth/ mDefaultHeight
uint32_t mUserHeight	
sp<GraphicBuffer> mLockedBuffer	访问这3个变量需要资源锁的保护，接下来还会有分析
sp<GraphicBuffer> mPostedBuffer	
Region mDirtyRegion	

从这些内部变量的描述中，大家可以了解到两点：Surface将通过mGraphicBufferProducer来获取buffer，而且这些缓冲区会被记录在mSlots数组中。接下来我们分析其中的实现细节。

前面Surface构造函数里大家看到ANativeWindow中的函数指针赋予的是各种以hook开头的函数，而这些hook_XX内部又直接“钩住”了Surface中真正的实现。比如hook_dequeueBuffer对应的是dequeueBuffer——这就好像“钩子”的功能一样，所以得名为hook：

```
int Surface::dequeueBuffer(android_native_buffer_t** buffer,int *
    Mutex::Autolock lock(mMutex);
    int buf = -1;
    /*Step1. 宽高计算*/
    int reqW = mReqWidth ? mReqWidth : mUserWidth;
    int reqH = mReqHeight ? mReqHeight : mUserHeight;
    /*Step2. dequeueBuffer得到一个缓冲区*/
    sp<Fence> fence;
    status_t result = mGraphicBufferProducer->dequeueBuffer(&buf,
                           reqW, reqH, mReqFormat, mReqUsage);/*生
    …
sp<GraphicBuffer>&gbuf(mSlots[buf].buffer);/*注意buf是一个int值，
                                            代表的是mSlots数组序号*/
```

```
    …
    if ((result & IGraphicBufferProducer::BUFFER_NEEDS_REALLOCATI
        result = mGraphicBufferProducer->requestBuffer(buf, &gbuf
        …
    }
    …
    *buffer = gbuf.get();
}
```

Step1@Surface::dequeueBuffer。图形缓冲区一定有宽高属性，具体的值由mReqWidth/ mReqHeight或者mUserWidth/mUserHeight决定，其中前者的优先级比后者高。

Step2@Surface::dequeueBuffer。如前面所述，真正执行dequeueBuffer操作的确实是mGraphicBufferProducer(IGraphicBufferProducer)。Surface中的这个核心成员变量的来源可以有两个：作为Surface的构造函数参数传入；或者Surface的子类通过直接调用setIGraphicBufferProducer来生成。

在应用进程环境中，属于后者。

大致流程是：ViewRootImpl持有一个Java层的Surface对象（即mSurface），初始时是空的。后续ViewRootImpl将向WindowManagerService发起relayout请求，此时mSurface才被赋予真正有效的值。WindowManagerService会先让WindowStateAnimator生成一个SurfaceControl，然后通过Surface.copyFrom()函数将其复制到mSurface中。这个复制函数会通过native接口nativeCreateFrom SurfaceControl来生成本地Surface(C++)对象，具体是在android_view_Surface.cpp文件中。JNI函数nativeCreateFromSurfaceControl将从SurfaceControl中提取出Surface(C++)，最终记录到Surface(Java)的成员变量中。这样，后期我们就可以从此变量中还原出底层的Surface对象了。

Android源码工程中有很多类的名称都带有“Surface”，取名极其混乱。下面通过图9-13来帮助大家理顺它们的关系。

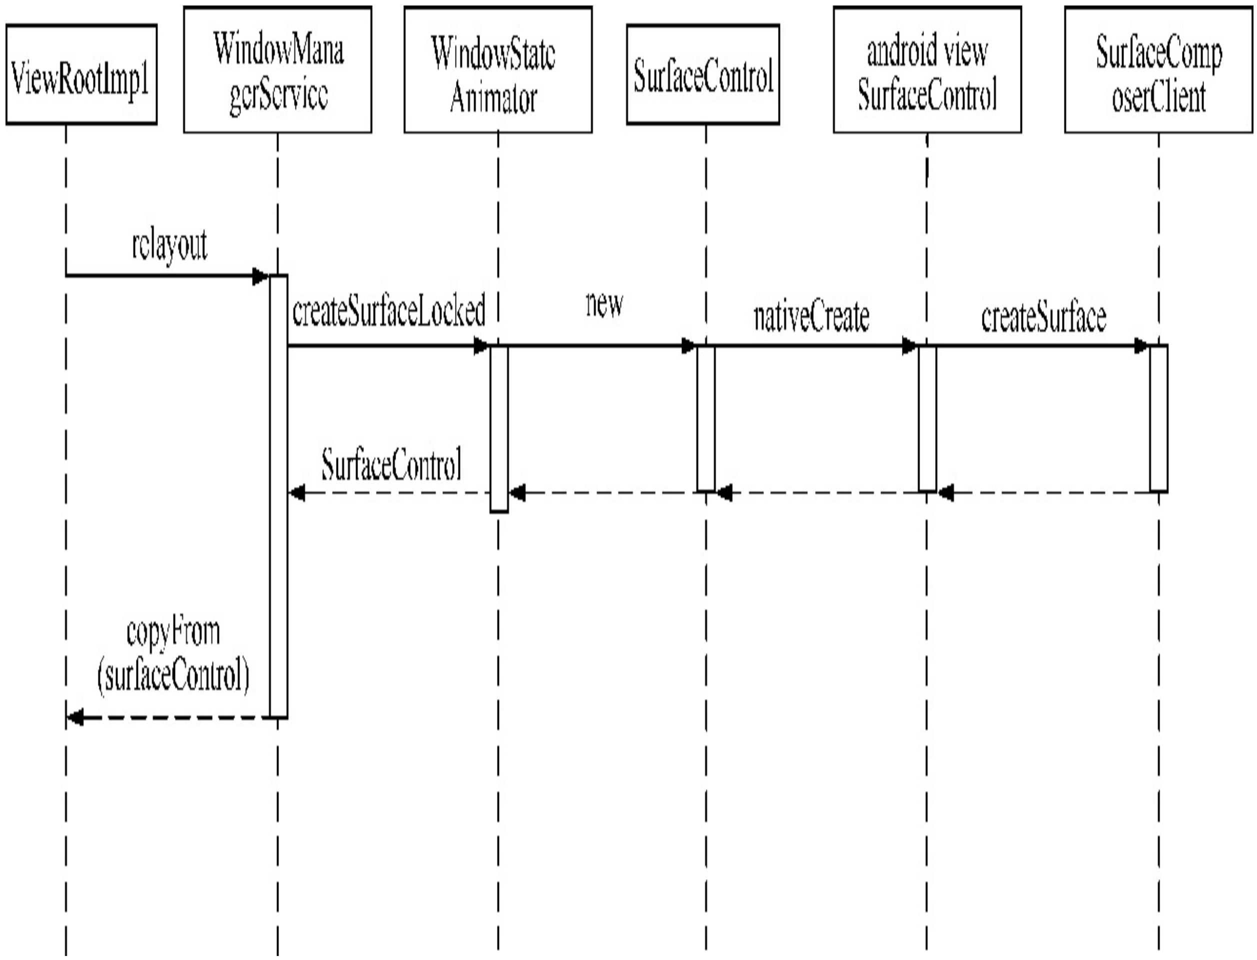

▲图9-13　Surface创建流程

从图9-13中可以看到，Surface由SurfaceControl管理，而后者又由SurfaceComposerClient创建。我们可以感觉到，程序应该越来越接近SurfaceFlinger了：

```
/*frameworks/native/libs/gui/SurfaceComposerClient.cpp*/
sp<SurfaceControl> SurfaceComposerClient::createSurface(const Str
                                               uint32_t h,PixelFormat for
{
    sp<SurfaceControl> sur;
    if (mStatus == NO_ERROR) {
        sp<IBinder> handle;
        sp<IGraphicBufferProducer> gbp;
        status_t err = mClient->createSurface(name, w, h, format,
        //生成一个Surface
        …
        if (err == NO_ERROR) {
            sur = new SurfaceControl(this, handle, gbp);//Surface
```

```
        }
    }
    return sur;
}
```

上述代码段中，mClient是一个ISurfaceComposerClient的sp指针，程序通过它来生成一个Surface。值得注意的是，SurfaceControl对象并不是由ISurfaceComposerClient的createSurface直接生成的——此函数的参数中包括了gbp，即前面所说的“buffer生产者”。从中我们可以了解到，真正与SurfaceFlinger间有联系的应该就是gbp。

ISurfaceComposerClient的服务器端实现是谁？

```
void SurfaceComposerClient::onFirstRef() {
    sp<ISurfaceComposer> sm(ComposerService::getComposerService()
    if (sm != 0) {
        sp<ISurfaceComposerClient> conn = sm->createConnection();
        if (conn != 0) {
            mClient = conn;
            mStatus = NO_ERROR;
        }
    }
}
```

由此可见，ISurfaceComposerClient是由ISurfaceComposer::createConnection生成的。在这一过程中，总共涉及了3个匿名的Binder Server，它们所提供的接口如表9-5所示。

表9-5　与Surface相关的3个匿名Binder服务

匿名**Binder**	提供的接口
ISurfaceComposer	createConnection
ISurfaceComposerClient	virtual status_tcreateSurface(…,sp<IGraphicBufferProduce gbp)=0;virtual status_t destroySurface(const sp<IBinder>& handle) = 0;

IGraphicBufferProducer	status_t requestBuffer(int slot, sp<GraphicBuffer>* buf);status_t setBufferCount(int bufferCount);status dequeueBuffer(…);status_t queueBuffer(…);void cancelBuffer(int slot);int query(int what, int* value);status_t setSynchronousMode(bool enabled);status_t connect(int api, QueueBufferOutp output);status_t disconnect(int api);

表中的3个匿名Binder是环环紧扣的，即我们访问的顺序只能是ISurfaceComposer Isurface ComposerClientIGraphicBufferProducer。当然，匿名Binder一定是需要由一个实名Binder来提供的，它就是SurfaceFlinger——这个系统服务是在ServiceManager中“注册在案”的。具体是在SurfaceComposerClient::onFirstRef()这个函数中，通过向ServiceManager查询名称为“SurfaceFlinger”的Binder Server来获得的。不过和其他常见Binder Server不同的是，SurfaceFlinger虽然在ServiceManager中注册的名称为“SurfaceFlinger”，但它在服务器端实现的Binder接口却是ISurfaceComposer，因而SurfaceComposerClient得到的其实是ISurfaceComposer。大家要特别注意这点，否则可能会引起混乱：

```
//我们可以从SurfaceFlinger的继承关系中看出这一区别，如下代码片断
class SurfaceFlinger :
      public BinderService<SurfaceFlinger>, //在ServiceManager中注
      public BnSurfaceComposer, //实现的接口却叫ISurfaceComposer，不
```

绕了一大圈，我们接着分析前面Surface::dequeueBuffer函数的实现。目前读者应该已经清楚mGraphicBufferProducer的由来了。接下来程序利用这个变量来dequeueBuffer。

那么，IGraphicBufferProducer在服务器端又是由谁来实现的呢？

因为这里面牵扯到很多新的类，我们先不做过多解释，到后面BufferQueue小节再详细分析其中的依赖关系。

当mGraphicBufferProducer->dequeueBuffer返回后，buf变量就是mSlots[]数组中可用的成员序号。接下来就要通过这个序号来获取真正

的buffer地址，即mSlots[buf].buffer。

Step3@Surface::dequeueBuffer。假如返回值result中的标志包含了BUFFER_NEEDS_REALLOCATION，说明BufferQueue需要为这个Slot重新分配空间，具体细节请参见下一个小节。此时还需要另外调用requestBuffer来确定gbuf的值，其中又牵涉到很多东西，也放在下一小节统一解释。

通过这两个小节的学习，大家已经掌握了显示系统中两个重要的本地窗口，即Framebuffer Nativewindow和Surface。第一个窗口是专门为SurfaceFlinger服务的，它由Gralloc提供支持，逻辑上相对好理解；而Surface虽然是为应用程序服务的，但本质上还是由SurfaceFlinger服务统一管理的，因而涉及很多跨进程的通信细节。这个小节我们只是简单地勾勒出其中的框架，接下来就要分几个方面来做完整的分析了。

- BufferQueue

为应用程序服务的本地窗口Surface，其依赖的IGraphicBufferProducer对象在Server端的实现是BufferQueue。我们将详细解析BufferQueue的内部实现，并结合应用程序端的使用流程来理解它们之间的关系。

- Buffer，Consumer，Producer是“生产者-消费者”模型中的3个参与对象，如何协调好它们的工作是应用程序能否正常显示UI的关键。接下来，我们先讲解Buffer(BufferQueue)与Producer（应用程序）间的交互，然后转而切入Consumer(SurfaceFlinger)做详细分析。

9.5 BufferQueue详解

上一小节我们已经看到了BufferQueue，它是Surface实现本地窗口的关键。从逻辑上来推断，BufferQueue应该是驻留在SurfaceFlinger这边的进程中。我们需要进一步解决的疑惑是：

- 每个应用程序可以有几个BufferQueue，即它们的关系是一对一、多对一，还是一对多？

- 应用程序绘制UI所需的内存空间是由谁来分配的？
- 应用程序与SurfaceFlinger如何互斥共享数据区？

我们这里面临的是经典的“生产者-消费者”模型。Android显示系统是如何协调好这两者对缓冲区的互斥访问的呢？

9.5.1 BufferQueue的内部原理

先来解析下BufferQueue的内部构造，如图9-14所示。

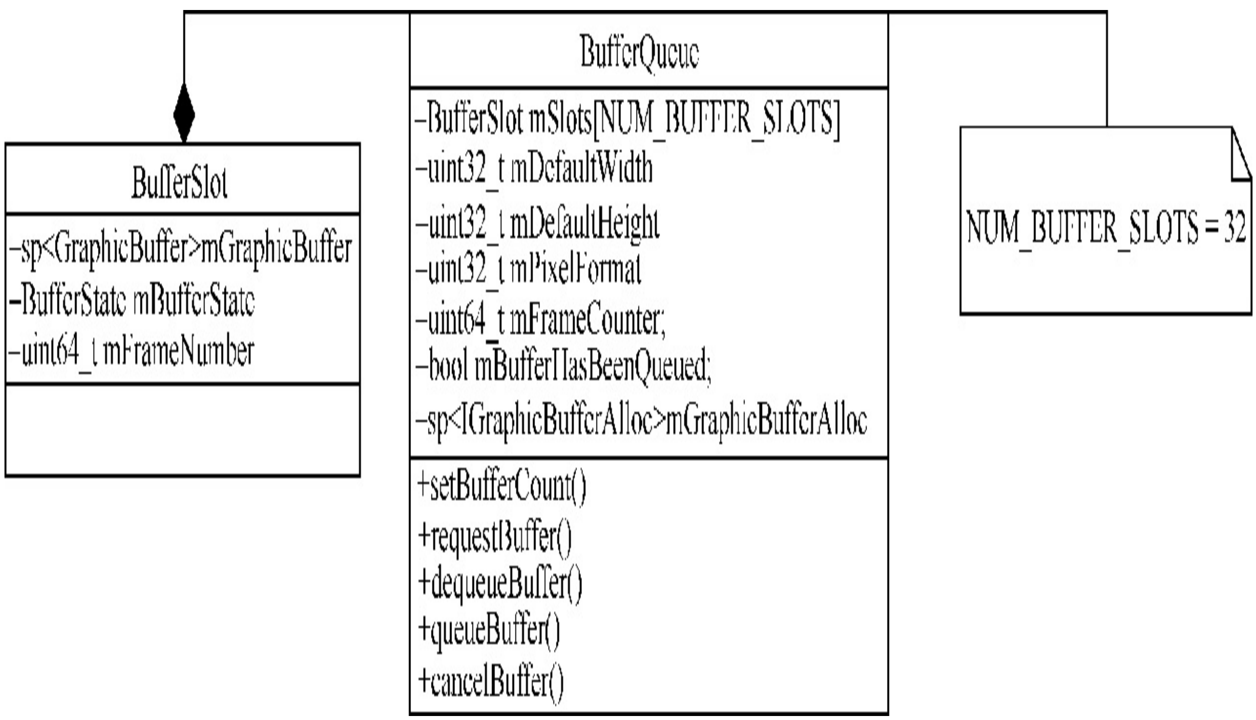

▲图9-14　BufferQueue内部变量

因为BufferQueue是IGraphicBufferProducer服务器端的实现，所以它必须重载接口中的各种虚函数，如queueBuffer、requestBuffer、dequeueBuffer等。另外，这个类的内部有一个非常重要的成员数组，即mSlots[NUM_BUFFER_SLOTS]。大家是否还记得前面Surface类中也有一个一模一样的数组：

```
class Surface…{
     BufferSlot mSlots[NUM_BUFFER_SLOTS];
```

虽然两个数组从形式上看一模一样，但要特别注意其中的BufferSlot定义并不相同：

```
Surface中：
    struct BufferSlot {
        sp<GraphicBuffer> buffer;
        Region dirtyRegion;
    };
```

而BufferQueue中：

```
struct BufferSlot {…
     sp<GraphicBuffer> mGraphicBuffer;
     BufferState mBufferState;
     …
}
```

后面一个BufferSlot中的GraphicBuffer变量（mGraphicBuffer）用于记录这个Slot所涉及的缓冲区；另一个BufferState变量（mBufferState）用于跟踪每个缓冲区的状态。比如：

```
        enum BufferState {
            FREE = 0, /*Buffer当前可用，也就是说可以被dequeued。此时Bu
                           可认为是BufferQueue*/
            DEQUEUED = 1, /*Buffer已经被dequeued，还未被queued或canc
                              Buffer的owner可认为是producer（应用程序），
                              和 SurfaceFlinger(consumer)此时都不可以操作
            QUEUED = 2, /*Buffer已经被客户端queued，不过还不能对它进行d
                              可以acquired。此时的owner是BufferQueue*/
            ACQUIRED = 3/*Buffer的owner改为consumer，可以被released，
                              然后状态又返回FREE*/
        };
```

从上面的状态描述可以看出，一块Buffer在处理过程中经历的生命周期依次是FREE-> DEQUEUED->QUEUED->ACQUIRED->FREE。

图9-15所示是从Owner的角度给出的Buffer状态迁移图。

我们来简单分析一下这张Buffer状态迁移图。

从图9-15中可以清楚地了解Buffer的各个状态、引起状态迁移的条件以及各状态下的Owner。参与Buffer管理的Owner对象有3个。

- BufferQueue

我们可以认为BufferQueue是一个服务中心，其他两个Owner必须要通过它来管理Buffer。比如当Producer想要获取一个Buffer时，它不能越过BufferQueue直接与Consumer进行联系，反之亦然。这有点像房产中介，房主与买方的任何交易都需要经过中介的同意，私自达成的协议都是违反规定的。

- Producer

生产者就是“填充”Buffer数据的人，通常情况下当然就是应用程序。因为应用程序不断地刷新UI，从而将产生的显示数据源源不绝地写到Buffer中。当Producer需要使用一块Buffer时，它首先会向中介BufferQueue发起dequeue申请，然后才能对指定的缓冲区进行操作。经过dequeue后Buffer就属于producer的了，它可以对Buffer进行任何必要的操作，而其他Owner此刻绝不能擅自插手。

当生产者认为一块Buffer已经写入完成后，将进一步调用BufferQueue的queue接口。从字面上看这个函数是“入列”的意思，形象地表达了Buffer此时的操作——把Buffer归还到BufferQueue的队列中。一旦queue成功，Owner也就随之改变为BufferQueue了。

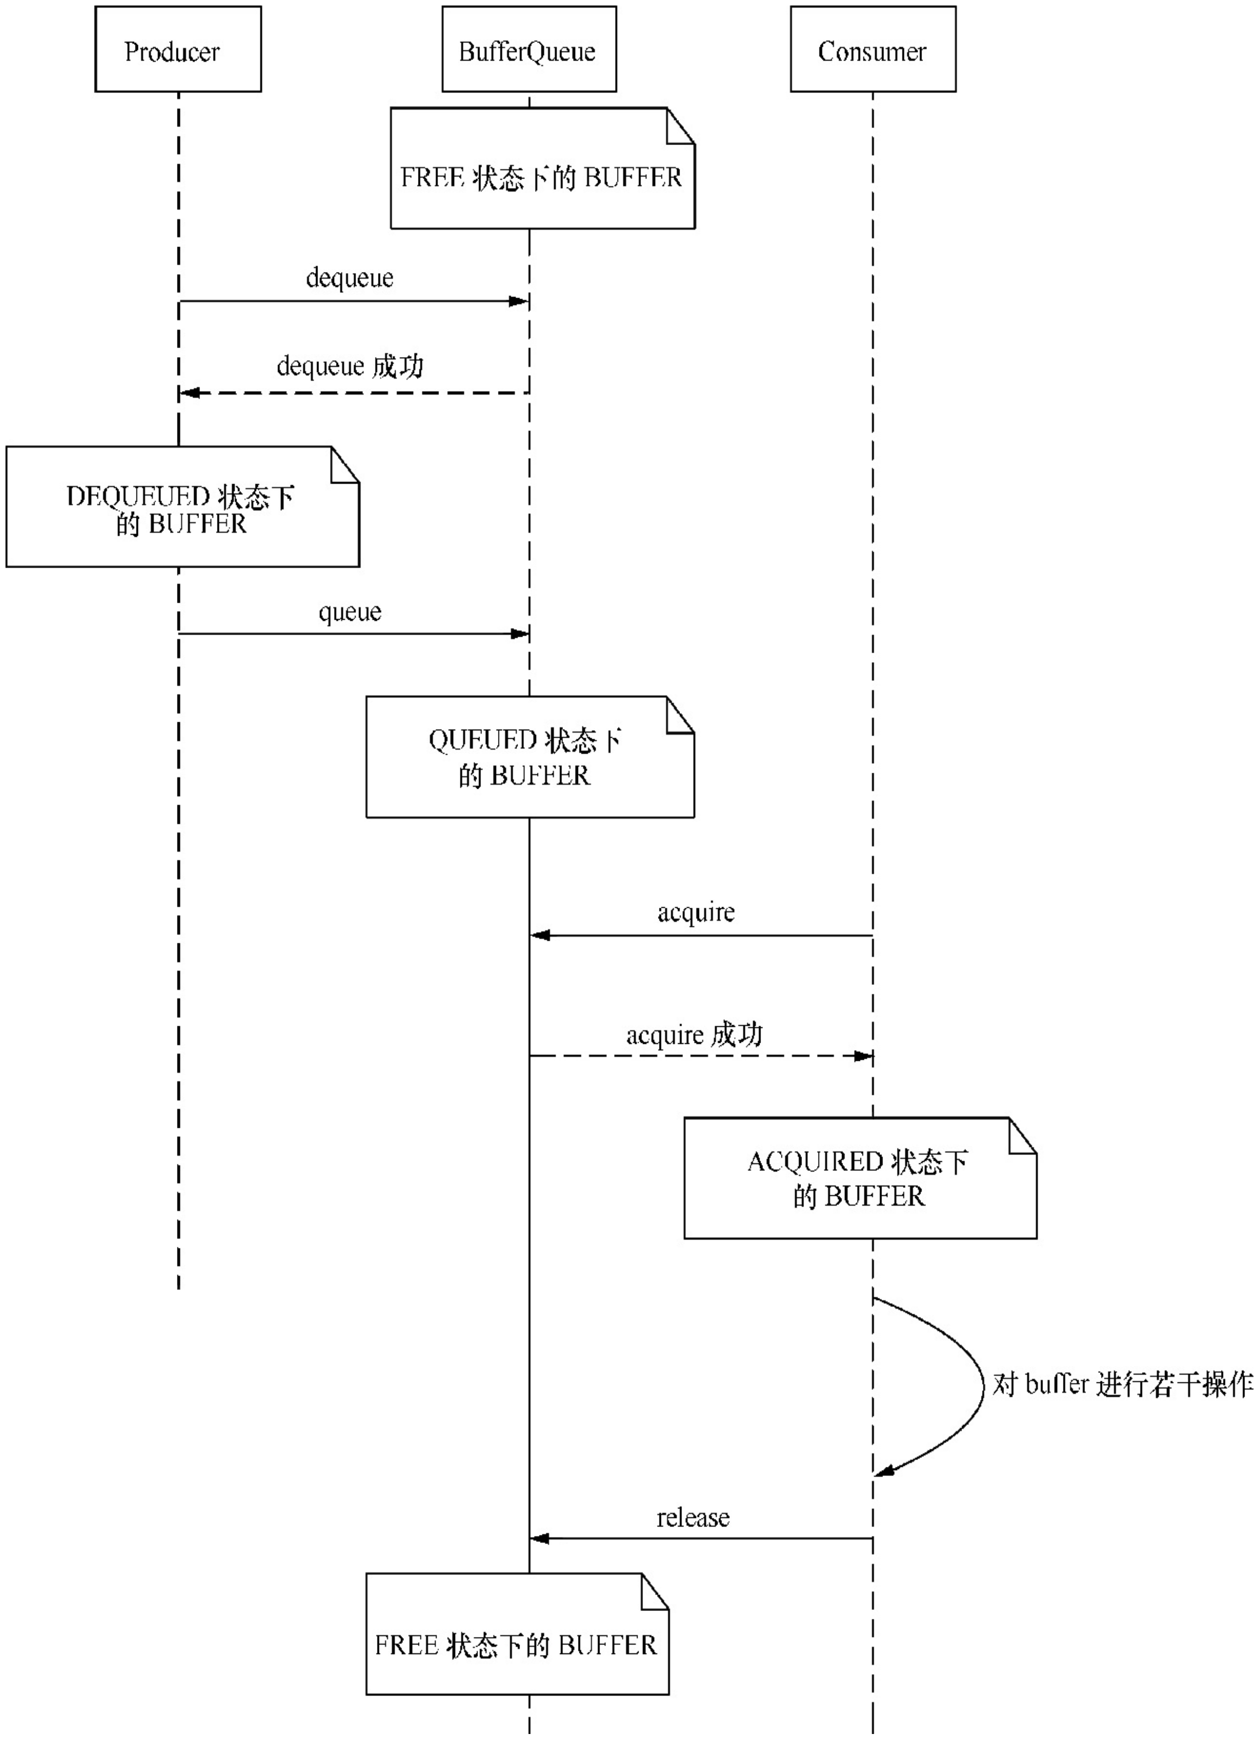
Producer
BufferQueue
Consumer
FREE 状态下的 BUFFER
dequeue
dequeue 成功
DEQUEUED 状态下的 BUFFER
queue
QUEUED 状态下的 BUFFER
acquire
acquire 成功
ACQUIRED 状态下的 BUFFER
对 buffer 进行若干操作
release
FREE 状态下的 BUFFER

▲图9-15 Buffer的状态迁移图

- Consumer

消费者是与生产者相对应的，它的操作同样受到BufferQueue的管控。当一块Buffer已经就绪后，Consumer就可以开始工作了，细节我们会在后续SurfaceFlinger中描述。这里需要特别留意的是，从各个对象所扮演的角色来看，BufferQueue是中介机构，属于服务提供方；Producer属于Buffer内容的产出方，它对缓冲区的操作是一个“主动”的过程；反之，Consumer对Buffer的处理则是“被动”的、“等待式”的——它必须要等到一块Buffer填充完成后才能工作。在这样的模型下，我们怎么保证Consumer可以及时处理Buffer呢？换句话说，当一块Buffer数据ready后，应该怎么告知Consumer来操作呢？

仔细观察，可以看到BufferQueue里同时还提供了一个特别的类，名称为ConsumerListener。其中的函数接口包括：

```
struct ConsumerListener : public virtual RefBase {
    virtual void onFrameAvailable() = 0;/*当一块buffer可以被消费
                                        特别注意此时没有共享锁的保
    virtual void onBuffersReleased() = 0;/*BufferQueue通知cons
                                        中的一个或多个GraphicBu
};
```

这样就很清楚了，当有一帧数据准备就绪后，BufferQueue就会调用onFrameAvailable()来通知Consumer进行消费。

9.5.2 BufferQueue中的缓冲区分配

我们知道，BufferQueue中有一个mSlots数组用于管理其内的各缓冲区，最大容量为32。从它的声明方式来看，这个mSlots在程序一开始就静态分配了32个BufferSlot大小的空间。不过这并不代表其中的数据缓冲区也是一次性静态分配的，恰恰相反，从BufferSlot的内部变量指针mGraphicBuffer可以看出，缓冲区的空间分配应当是动态的（从下面的注释也能看出一些端倪）：

```
// mGraphicBuffer points to the buffer allocated for this slot or
       sp<GraphicBuffer> mGraphicBuffer;
```

现在的问题就转化为：在什么情况下会给一个Slot分配实际的空间呢？

首先能想到的就是dequeueBuffer。理由如下：

- 缓冲区的空间分配应该既要满足使用者的需求，又要防止浪费。后面这一点mSlots已经满足了，因为它并没有采取一开始就静态预分配的方式。

- 既然Producer对buffer的操作是“主动”的，那么就意味着它是整个需求的发起者。换句话说，只要它没有dequeueBuffer，或者dequeueBuffer时能获取到可用的缓冲区，那当然就没有必要再重新分配空间了。

下面详细分析这个函数，并验证我们上面的猜测：

```
/*frameworks/native/libs/gui/BufferQueue.cpp*/
status_t BufferQueue::dequeueBuffer(int *outBuf, sp<Fence>* outFe
                             uint32_t h,uint32_t format, uint32_t
    status_t  returnFlags(OK);
    …
    { // Scope for the lock
        Mutex::Autolock lock(mMutex); /*这里采用了自动锁，所以上面需要
                                       生命周期结束后锁也就自动释放了。这种写法
        …
        int found = -1;
        int dequeuedCount = 0;
        bool tryAgain = true;
        while (tryAgain) {/*Step1. 循环查找符合要求的Slot*/
            …
            found = INVALID_BUFFER_SLOT;//初始值
            foundSync = INVALID_BUFFER_SLOT;
            dequeuedCount = 0;
            for (int i = 0; i < maxBufferCount; i++) {
                const int state = mSlots[i].mBufferState;
                /*Step2.统计dequeued buffer数量，后面会用到*/
                if (state == BufferSlot::DEQUEUED) {
                    dequeuedCount++;
                }

                if (state == BufferSlot::FREE) { /*Step3.寻找符合要
                 if (found < 0 || mSlots[i].mFrameNumber < mSlots
                        found = i; //找到符合要求的Slot
                  }
```

```
            }// if (state == BufferSlot::FREE)结束
        }// for循环结束

        /*Step4.如果Client没有设置buffer count的话，就不允许dequeue
         if (!mOverrideMaxBufferCount&& dequeuedCount) {
             ST_LOGE("dequeueBuffer: can't dequeue multiple bu
                        setting the buffer count");
             return -EINVAL;
         }
         …
         /*Step5. 判断是否要重试*/
         tryAgain = found == INVALID_BUFFER_SLOT;
         if (tryAgain) {
             mDequeueCondition.wait(mMutex);
         }
    }//while循环结束

    if (found == INVALID_BUFFER_SLOT) {
        /*因为前面while循环如果没找到的话是不会退出的，所以理论上不会出
        ST_LOGE("dequeueBuffer: no available buffer slots");
        return -EBUSY;
    }

    const int buf = found;
    *outBuf = found; //返回值
   /*成功找到可用的Slot序号，接下来就开始对这个指定的Slot进行初始操作，
   …
    mSlots[buf].mBufferState = BufferSlot::DEQUEUED;/*Step6.
    const sp<GraphicBuffer>& buffer(mSlots[buf].mGraphicBuffe
    if ((buffer == NULL) || (uint32_t(buffer->width)  != w) |
        (uint32_t(buffer->height) != h) || (uint32_t(buffer->
             || ((uint32_t(buffer->usage) & usage) != usage))
    {   /*Step7. 为BufferSlot对象做初始化*/
        mSlots[buf].mAcquireCalled = false;
        mSlots[buf].mGraphicBuffer = NULL;
        mSlots[buf].mRequestBufferCalled = false;
        mSlots[buf].mEglFence = EGL_NO_SYNC_KHR;
        mSlots[buf].mFence = Fence::NO_FENCE;
        mSlots[buf].mEglDisplay = EGL_NO_DISPLAY;

        returnFlags |= IGraphicBufferProducer::BUFFER_NEEDS_R
    }
      …
}  // 自动锁lock结束的地方

/*Step8. 如果上述判断结果是需要重新分配空间的话*/
if (returnFlags & IGraphicBufferProducer::BUFFER_NEEDS_REALLO
    status_t error;
```

```
        sp<GraphicBuffer> graphicBuffer(mGraphicBufferAlloc->crea
                        w, h, format, usage, &error));/*终于分配空间
        …
        { // Scope for the lock
            Mutex::Autolock lock(mMutex);
               …
            mSlots[*outBuf].mGraphicBuffer = graphicBuffer;
        }
    }
    …
    return returnFlags;
}
```

因为这个函数很长，我们只保留最核心的部分。从整体框架来看，Step1～Step5是在查找一个可用的Slot序号。从Step6开始，就针对这一特定的Slot进行操作了。下面我们分步进行解析。

Step1@ BufferQueue::dequeueBuffer。进入while循环，退出的条件是tryAgain为false。这个变量默认值是true，如果一轮循环结束后found不再是INVALID_BUFFER_SLOT，就会变成false，从而结束整个while循环。

循环的主要功能就是查找符合要求的Slot，其中found变量是一个int值，指的是这个BufferSlot在mSlots数组中的序号。

Step2@ BufferQueue::dequeueBuffer。统计当前已经被dequeued的buffer数量，这将用于后面的判断，即假如Client没有设置buffer count，那么它会被禁止dequeue一个以上的buffer。

Step3@ BufferQueue::dequeueBuffer。假如当前的buffer状态是FREE，那么这个Slot就可以进入备选了。为什么只是备选而不是直接返回这一结果呢？因为mSlots中很可能有多个符合条件的Slot，当然需要挑选其中最匹配的。判断的依据是当前符合要求的Slot的mFrameNumber是否比上一次选中的最优Slot的mFrameNumber小。具体代码如下：

```
mSlots[i].mFrameNumber <mSlots[found].mFrameNumber;
```

Step4@ BufferQueue::dequeueBuffer。这里的判断来源于第二步的计算结果，一旦发现dequeue的数量“超标”，就直接出错返回。

Step5@ BufferQueue::dequeueBuffer。经过上述几个步骤，我们

已经扫描了一遍mSlots中的所有成员，这时就要判断是否可以退出循环。前面已经说过，如果成功找到有效的Slot就可以不用再循环查找了，否则tryAgain仍然是true。假如是后一种情况，证明当前已经没有FREE的Slot。这时如果直接进入下一轮循环，结果通常也是一样的，反而浪费了CPU资源。所以，就需要使用条件锁来等待。代码如下：

```
mDequeueCondition.wait(mMutex);
```

当有Buffer被释放时，这个锁的条件就会满足，然后程序才继续查找可用的Slot。

Step6@ BufferQueue::dequeueBuffer。根据前面的Buffer状态迁移图，当处于FREE状态的Buffer被dequeue成功后，它将进入DEQUEUED，所以这里我们需要改变其mBufferState。

Step7@ BufferQueue::dequeueBuffer。通过上述几个步骤的努力，现在我们已经成功地寻找到有效的Slot序号了。但是这并不代表这个Slot可以直接使用，为什么？最直接的一个原因就是这个Slot可能还没有分配空间。

因为BufferSlot:: mGraphicBuffer初始值是NULL，假如我们是第一次使用它，必然是需要为它分配空间的。另外，即便mGraphicBuffer不为空，但如果用户所需要的Buffer属性（比如width，height，format等）和当前这个不符，那么还是要进行重新分配。

Step8@ BufferQueue::dequeueBuffer。如果上一步的判断结果是BUFFER_NEEDS_REALLOCATION，说明此Slot还未分配到有效的buffer空间——具体分配操作使用的是mGraphicBufferAlloc这个Allocator，这里暂不深究其中的实现了，后续还会有详细分析。

如果重新分配了空间，那么最后的返回值中需要加上BUFFER_NEEDS_REALLOCATION标志。客户端在发现这个标志后，还应调用requestBuffer()来取得最新的buffer地址。前一小节Surface::dequeueBuffer()的Step3就是一个例子，这里结合起来分析。为了方便阅读，再把这部分代码简单地列出来：

```
int Surface::dequeueBuffer(android_native_buffer_t** buffer,int *
    Mutex::Autolock lock(mMutex);
    int buf = -1;
```

```
    /*Step1. 宽高计算*/
    int reqW = mReqWidth ? mReqWidth : mUserWidth;
    int reqH = mReqHeight ? mReqHeight : mUserHeight;
    /*Step2. dequeueBuffer得到一个缓冲区*/
    sp<Fence> fence;
    status_t result = mGraphicBufferProducer->dequeueBuffer(&buf,
           reqW, reqH, mReqFormat, mReqUsage);/*这一小节讲解的就是这
    …
sp<GraphicBuffer>&gbuf(mSlots[buf].buffer);/*注意buf是一个int值，
                                                代表的是mSlots数组序号*
    …
    if ((result & IGraphicBufferProducer::BUFFER_NEEDS_REALLOCATI
        result = mGraphicBufferProducer->requestBuffer(buf, &gbuf
                                 要重新分配得到的，所以还需要进一步调用requestBu
        …
    }
    …
    *buffer = gbuf.get();
}
```

当mGraphicBufferProducer->dequeueBuffer成功返回后，buf得到了mSlots中可用数组成员的序号（对应这一小节的found变量）。但一个很明显的问题是：既然客户端和BufferQueue运行于两个不同的进程中，那么它们的mSlots[buf]会指向同一块物理内存吗？这就是requestBuffer存在的意义。

先来看看BpGraphicBufferProducer中是如何发起Binder申请的：

```
/*frameworks/native/libs/gui/IGraphicBufferProducer.cpp*/
class BpGraphicBufferProducer: public BpInterface<IGraphicBufferP
{ …
      virtual status_t requestBuffer(int bufferIdx, sp<GraphicBuf
      Parcel data, reply;
      data.writeInterfaceToken(IGraphicBufferProducer::getInterfa
      data.writeInt32(bufferIdx);/*只写入了bufferIdx值，也就是说BnGra
                                        中实际上是看不到buf变量的*/
      status_t result =remote()->transact(REQUEST_BUFFER, data, &
      …
      bool nonNull = reply.readInt32();/*这里读取的是什么？我们稍后可
                                              Producer中确认下*/
      if (nonNull) {
          *buf = new GraphicBuffer(); //生成一个GraphicBuffer，看到
          reply.read(**buf);/*buf是一个sp指针,那么**sp实际上得到的就是
                                   象。在这个例子中指的是mSlots[buf].buffer
      }
      result = reply.readInt32();/*读取结果*/
```

```
    return result;
}
```

Native层的BpXXX/BnXXX与Java层的不同之处在于，后者通常都是依赖于aidl来自动生成这两个类，而前者则是手工完成的。也正因为是手工书写的，使用起来才更具灵活性。比如在IGraphicBufferProducer这个例子中，开发者“耍”了点技巧——Surface中调用了IgraphicBuffer Producer::requestBuffer(int slot, sp<GraphicBuffer>* buf)，这个函数虽然形式上有两个参数，但只有第一个是入参，后一个则是出参。在实际的Binder通信中，只有Slot序号这个int值（即bufferIdx）传递给了对方进程，而buf则自始至终都是Surface所在的本地进程在处理。不过从调用者的角度来讲，好像是由IGraphicBufferProducer的Server端完成了对buf的赋值。

从BpGraphicBufferProducer::requestBuffer这个函数实现中可以看到，Client端向Server端请求了一个REQUEST_BUFFER服务，然后通过读取返回值来获得缓冲区信息。为了让大家能看清楚这其中的细节，有必要再分析一下BnGraphicBufferProducer具体是如何响应这个服务请求的。如下所示：

```
/*frameworks/native/libs/gui/IGraphicBufferProducer.cpp*/
status_t BnGraphicBufferProducer::onTransact(uint32_t code, const
{
    switch(code) {
        case REQUEST_BUFFER: {
            CHECK_INTERFACE(IGraphicBufferProducer, data, reply);
            int bufferIdx   = data.readInt32();//首先读取要处理的Slo
            sp<GraphicBuffer> buffer; //生成一个GraphicBuffer智能指
            int result = requestBuffer(bufferIdx, &buffer);//调用
            reply->writeInt32(buffer != 0);//注意，第一个写入的值是判
                                         //也就是一个bool值
            if (buffer != 0) {
                reply->write(*buffer); //好，真正的内容在这里，后面我
            }
            reply->writeInt32(result);//写入结果值
            return NO_ERROR;
        } break;
```

BnGraphicBufferProducer首先读取Slot序号，即bufferIdx；然后通过BufferQueue的接口requestBuffer来获取与之对应的正确的GraphicBuffer——这里是指mSlots[slot].mGraphicBuffer。要特别注意的是，BnGraphicBufferProducer在reply中第一个写入的是bool值

（buffer!=0），紧随其后的才是GraphicBuffer，最后写入结果值，大功告成。

显然BpGraphicBufferProducer必须要按照与BnGraphicBufferProducer同样的写入顺序来读取数据。

（1）因而它首先获取一个int32值，赋予nonNull变量。这个值对应的是buffer != 0的逻辑判断。假如确实不为空，那说明我们可以接着读取GraphicBuffer了。

（2）客户端与服务器端对GraphicBuffer变量的“写入和读取”操作分别是：

```
reply->write(*buffer);//写入
reply.read(**buf);//读取
```

（3）读取result结果值。

在第二步中，Server端写入的GraphicBuffer对象需要在Client中完整地复现出来。根据我们在Binder章节的学习，具备这种能力的Binder对象应该是继承了Flattenable。实际上呢？

```
class GraphicBuffer: public ANativeObjectBase<ANativeWindowBuffer
        LightRefBase<GraphicBuffer>>, public Flattenable
```

从GraphicBuffer的声明中就可以验证我们的猜测了。

接下来只需要看下它是如何实现flatten和unflatten接口的，相信就能揭晓谜底了：

```
/*frameworks/native/libs/ui/GraphicBuffer.cpp*/
status_t GraphicBuffer::flatten(void* buffer, size_t size, int fd
{…
    int* buf = static_cast<int*>(buffer);
    …
    if (handle) {
        buf[6] = handle->numFds;
        buf[7] = handle->numInts;
        native_handle_t const* const h = handle;
        memcpy(fds, h->data, h->numFds*sizeof(int));
        memcpy(&buf[8], h->data + h->numFds, h->numInts*sizeof(in
    }
```

```
    return NO_ERROR;
}
```

在这个函数中，我们最关心的是handle这个变量的flatten，它实际上是GraphicBuffer中打开的一个ashmem句柄——这是两边进程实现共享缓冲区的关键。与handle相关的变量分别是buf[6]-buf[8]以及fds，大家可以深入理解下它们的作用。

再来看看Client端是如何还原出一个GraphicBuffer的：

```
status_t GraphicBuffer::unflatten(void const* buffer, size_t size
{…
    int const* buf = static_cast<int const*>(buffer);
    …
    const size_t numFds  = buf[6];
    const size_t numInts = buf[7];
    …
    if (numFds || numInts) {…
        native_handle* h = native_handle_create(numFds, numInts);
        memcpy(h->data, fds, numFds*sizeof(int));
        memcpy(h->data + numFds, &buf[8], numInts*sizeof(int));
        handle = h;
    } else { …
    }…
    if (handle != 0) {
        mBufferMapper.registerBuffer(handle);
    }
    return NO_ERROR;
}
```

同样，unflatten中的操作也是依据flatten时写入的格式。其中最重要的两个函数是native_handle_create()和registerBuffer()。前一个函数生成native_handle实例，并将相关数据复制到其内部。另一个registerBuffer则属于GraphicBufferMapper类中的实现，成员变量mBufferMapper是在GraphicBuffer构造函数中生成的，它所承担的任务是和Gralloc打交道。核心代码如下：

```
GraphicBufferMapper::GraphicBufferMapper()
{
    hw_module_t const* module;
    int err = hw_get_module(GRALLOC_HARDWARE_MODULE_ID, &module);
```

这里出现了我们熟悉的Gralloc的module id，不清楚的读者可以回

头看看Gralloc这个小节的介绍。
GraphicBufferMapper::registerBuffer()只是起到了中介作用，它会直接调用gralloc_module_t::registerBuffer()，那么后者究竟完成了什么功能呢？因为这个函数的实现与具体平台有关，我们以msm7k为例来大概分析下：

```
/*hardware/msm7k/libgralloc/Mapper.cpp*/
int gralloc_register_buffer(gralloc_module_t const* module, buffe
{…
    private_handle_t* hnd = (private_handle_t*)handle;
    …
    err = gralloc_map(module, handle, &vaddr);
    return err;
}
```

可以看到，通过handle句柄Client端可以将指定的内存区域映射到自己的进程空间中，而这块区域与BufferQueue中所指向的物理空间是一致的，从而成功地实现了两者的缓冲区共享。

这样在Surface::dequeueBuffer()函数的处理过程中，一旦遇到mGraphicBufferProducer-> requestBuffer结果中包含有BUFFER_NEEDS_REALLOCATION的情况，就需要通过requestBuffer()得到的结果来“刷新”Client这端mSlots[]所管辖的缓冲区信息，以保证Surface与BufferQueue在任何情况下都能在32个BufferSlot中保持数据缓冲区上的高度一致。这也是后面它们能正确实施“生产者-消费者”模型的基础。

9.5.3 应用程序的典型绘图流程

我们知道，BufferQueue可以有多达32个的BufferSlot，为什么这样设计？

一个可能的原因就是提高图形渲染速度。因为假如只有两个buffer，可以想象一下，当应用程序这个生产者的产出效率大于消费者的处理速度时，很快就会dequeue完所有缓冲区而处于等待状态，从而导致不必要的麻烦。当然，实际上32只是最大的容量，具体值是可以设置的，大家可以结合后面的Project Butter来进一步理解。

前面小节读者已经学习了BufferQueue的内部原理，那么应用程序又是如何与之配合的呢？

解决这个疑惑的关键就是了解应用程序是如何执行绘图流程的，这也是本节内容的重点。不过大家应该有个心理准备——应用程序并不会直接使用BufferQueue（或者Surface）。和Android系统中很多其他地方一样，“层层封装”在这里同样是存在的。因而我们一方面要尽量抓住核心，另一方面也要辅以有效的分析手段，才能更快更好地从诸多错综复杂的类关系中找出问题的答案。

基于以上原因，我们特别选取“系统开机动画”这一应用程序为例，来分析应用程序图形绘制的流程。值得一提的是，这个开机动画的实现符合前面提到的两个改进图形系统中的第一个，即应用程序与SurfaceFlinger都是使用OpenGL ES来完成UI显示的。不过因为它是一个C++程序，所以不需要上层GLSurfaceView的支持。

当一个Android设备上电后，正常情况下它会先后显示最多4个不同的开机画面。分别是：

- BootLoader

这显然是第一个出现的画面。因为boot-loader只是负责系统后续模块的加载与启动，所以一般我们只让它显示一张静态的图片。

- Kernel

内核也有自己的显示画面。和boot-loader一样，默认情况下它也只是一张静态图片。

- Android（最多2个）

Android是系统启动的最后一个阶段，也是最耗时间的一个。它的开机画面既可以是静态的文字、图片，也可以是动态的画面。另外，这一阶段可以包含最多两个开机画面——通常前一个是文字或者静态图片（注意：默认是图片，但如果图片不存在的话，就显示文字。关于这方面的参考资料很多，大家可以自行查阅，这里不作过多叙述）；另外一个则是动画，如图9-16所示。

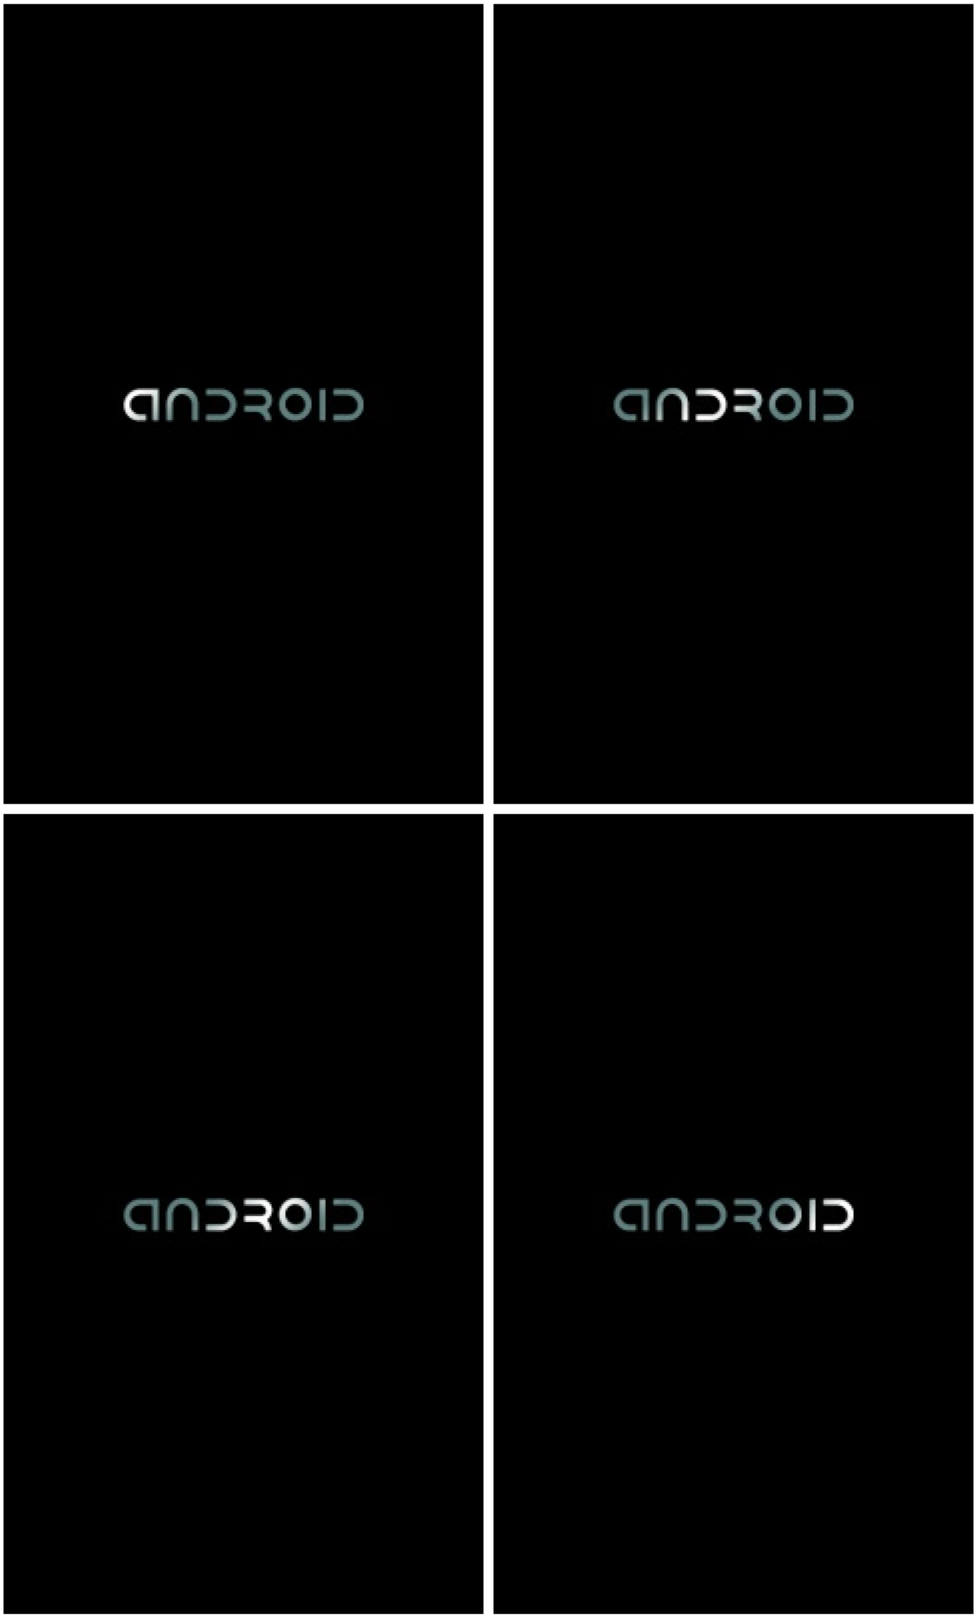

▲图9-16　原生态Android系统中的开机动画

这个开机动画的实现类是BootAnimation，它的内部就是借助于SurfaceFlinger来完成的。另外，由于它并不是传统意义上的Java层应用程序，从而使得我们可以抛离很多上层的牵绊（比如一大堆JNI调用），进而以最直观的方式来审视BufferQueue的使用细节，这是分析本节问题的最佳选择。

BootAnimation是一个C++程序，其工程源码路径是/frameworks/base/cmds/bootanimation。和很多native应用一样，它也是在init脚本中被启动的。如下：

```
service bootanim /system/bin/bootanimation
    class main
    user graphics
    group graphics
    disabled
    oneshot
```

以上内容是从init.rc脚本中摘录出来的，完整地描述了bootanimation这个程序的启动属性。如果大家对其中的语法不清楚，可以参见本书的系统启动章节。

当bootanimation被启动后，它首先会进入main函数（即main@Bootanimation_main.cpp）生成一个BootAnimation对象，并开启线程池（因为它需要与SurfaceFlinger等系统服务进行跨进程的通信）。在BootAnimation的构造函数中，同时会生成一个SurfaceComposerClient：

```
BootAnimation::BootAnimation() : Thread(false)
{
    mSession = new SurfaceComposerClient();
}
```

SurfaceComposerClient是每个UI应用程序与SurfaceFlinger间的独立纽带，后续很多操作都是通过它来完成的。不过SurfaceComposerClient更多的只是一个封装，真正起作用的还是其内部的ISurfaceComposerClient。前面小节中我们已经讲解了IGraphicBufferProducer与ISurface Composer Client在应用程序中的获取顺序，那么两者有什么区别呢？

简单来说，ISurfaceComposerClient是应用程序与SurfaceFlinger

间的桥梁，而IgraphicBuffer Producer则是应用程序与BufferQueue间的传输通道。这样的设计是合理的，体现了模块化的思想——SurfaceFlinger的职责是“Flinger”，即把系统中所有应用程序最终的“绘图结果”进行“混合”，然后统一显示到物理屏幕上。它不应该也没有办法分出太多的精力去逐一关注各个应用程序的“绘画过程”。这个光荣的任务自然而然地落在了BufferQueue的肩膀上，它是SurfaceFlinger派出的代表，也是每个应用程序“一对一”的辅导老师，指导着UI程序的“画板申请”、“作画流程”等一系列烦琐细节。图9-17描述了它们三者的关系。

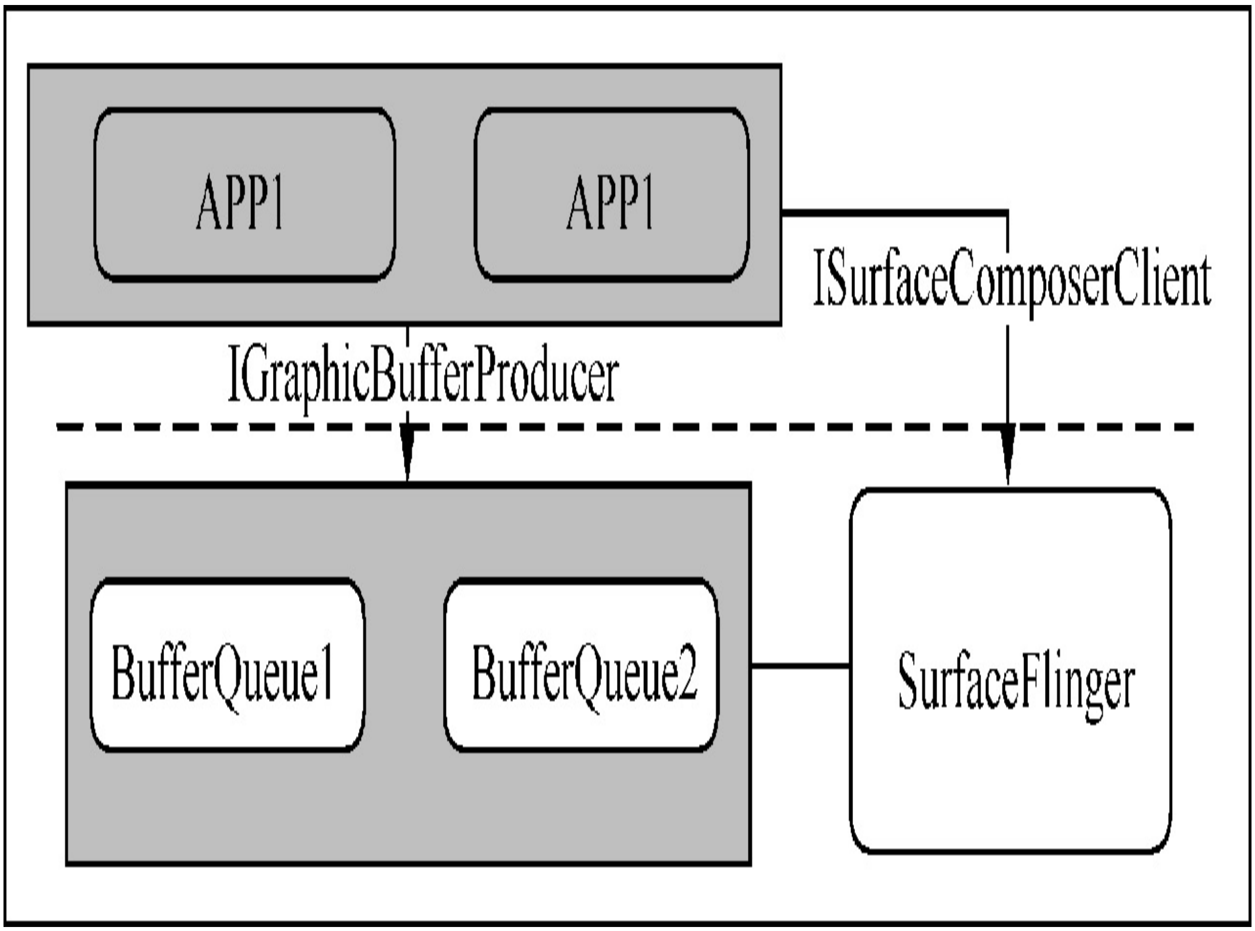

▲图9-17　应用程序、BufferQueue及SurfaceFlinger间的关系

所以BootAnimation在其构造函数中就建立了与SurfaceFlinger的连接通道。那么，它在什么时候会再去建立与BufferQueue的连接呢？因为BootAnimation继承自RefBase，当main函数中通过sp指针引用它时，会触发如下函数：

```
void BootAnimation::onFirstRef() {//第一次被引用时
    status_t err = mSession->linkToComposerDeath(this);//监听死亡事
    if (err == NO_ERROR) {
        run("BootAnimation", PRIORITY_DISPLAY);//开启线程
    }
}
```

当一个Client与远程Server建立了Binder通信后，它就可以使用这个Server的服务了，但前提是服务器运行正常。换句话说，假如出现了Server异常的情况，Client又如何知道呢？这就是linkToComposerDeath要解决的问题，它的第一个参数指明了接收Binder Server死亡事件的人，在本例中就是BootAnimation自身。所以BootAnimation继承了IBinder::DeathRecipient，并实现了其中的binderDied接口。

如果上一步没有出错的话（err == NO_ERROR），接下来就要启动一个新线程来承载业务了。为什么需要独立创建一个新的线程呢？前面main函数中，大家应该发现了BootAnimation启动了Binder线程池。可以想象在只有一个线程的情况下，它是不可能既监听Binder请求，又去做开机动画绘制的。当一个新的线程被run起来后，又触发了下列函数的调用：

```
status_t BootAnimation::readyToRun() {…
    /*第一部分，向server端获取buffer空间，从而得到EGL需要的本地窗口*/
    sp<SurfaceControl> control = session()->createSurface(String8
    dinfo.h,PIXEL_FORMAT_RGB_565);
    SurfaceComposerClient::openGlobalTransaction();
    control->setLayer(0x40000000);
    SurfaceComposerClient::closeGlobalTransaction();
    sp<Surface> s = control->getSurface();

    /*以下为第二部分，即EGL的配置流程*/
    const EGLint attribs[] = {…/*属性值较多，为了节约篇幅，我们省略具体
    EGLint w, h, dummy;
    EGLint numConfigs;//总共有多少个config
    EGLConfig config;
    EGLSurface surface;
    EGLContext context;
    EGLDisplay display = eglGetDisplay(EGL_DEFAULT_DISPLAY);//第一
    eglInitialize(display, 0, 0);//第二步，初始化
    eglChooseConfig(display, attribs, &config, 1, &numConfigs);//
    surface = eglCreateWindowSurface(display, config, s.get(), NU
                                                          //第四步，通
    context = eglCreateContext(display, config, NULL, NULL);//第五
```

```
    …
    if (eglMakeCurrent(display, surface, surface, context) == EGL
        return NO_INIT;
    …
    return NO_ERROR;
}
```

这个函数不但向我们展示了应用程序与BufferQueue的通信过程，而且还有另外一个重要的学习点，即Opengl ES与EGL的使用流程。本书的应用篇章已经给出了EGL的详细使用范例，这里则可以作为第二个例子。

函数readyToRun首先通过session()->createSurface()来获取一个SurfaceControl。其中session()得到的是mSession变量，也就是前面构造函数中生成的SurfaceComposerClient对象，所以createSurface()最终就是由SurfaceFlinger相关联的服务来实现的。具体而言，SurfaceComposerClient对应的Server端的实现是Client(C++)：

```
/*frameworks/native/services/surfaceflinger/Client.cpp*/
status_t Client::createSurface (…)
{…
    sp<MessageBase> msg = new MessageCreateLayer(mFlinger.get(),
              name, this, w, h, format, flags, handle, gbp);
    mFlinger->postMessageSync(msg);//发送给SurfaceFlinger进行处理
    return static_cast<MessageCreateLayer*>( msg.get() )->getResu
}
```

显然这个函数只是SurfaceFlinger的“秘书”，它将用户的请求通过消息推送到前者的处理队列中，等到有结果后才返回（从postMessageSync名称可以看出，这是一个同步函数）。关于Client与SurfaceFlinger间的这种工作方式，我们会放在后续SurfaceFlinger小节作详细解释。

因而最终还是要由SurfaceFlinger来执行操作，只不过“操作的内容”又是由Message本身提供的。

```
    class MessageCreateLayer : public MessageBase {…
    public:
      …
        virtual bool handler() {
           result = flinger->createLayer(name, client, w, h, form
           return true;
```

```
        }
    };
```

上述的处理过程在本书进程章节分析Handler，Looper等元素的关系时也有详细讲解，读者应该要习惯这种写法。现在的问题就转换为：createLayer生成了什么对象呢？

没错，就是IGraphicBufferProducer。

我们省略了中间一大段过程，只保留与问题相关的部分，更详细的分析可以参见后续小节：

```
status_t SurfaceFlinger::createLayer(…sp<IBinder>* handle, sp<IGr
{…
    status_t result = NO_ERROR;

    sp<Layer> layer;
    switch (flags & ISurfaceComposerClient::eFXSurfaceMask) {
        case ISurfaceComposerClient::eFXSurfaceNormal://普通Surfac
            result = createNormalLayer(client,name, w, h, flags,
            break;
        case ISurfaceComposerClient::eFXSurfaceDim:
            result = createDimLayer(client,name, w, h, flags,hand
            break;
        default:
            result = BAD_VALUE;
            break;
    }
    …
    return result;
}
```

通过上面的代码段可以清楚地看到，SurfaceFlinger不但生成了IGraphicBufferProducer对象，而且引入了新的概念——Layer。Layer类在SurfaceFlinger中表示“层”，通俗地讲就是代表了一个“画面”，最终物理屏幕上的显示结果就是通过对系统中同时存在的所有“画面”进行处理而得到的。这就好比一排人（列队）各举着一张绘画作品，那么观察者从最前面往后看时，他首先看到的就是第一张画；而假如第一张画恰好比第二张小，又或者第一张是透明/半透明的（这并非不可能，如作者是在玻璃上创作的），那么他就能看到第二张画。依此类推，最终看到的就是这些“画”（Layer）的混合（Flinger）结果。

这个类比告诉我们，layer是有层级的，越靠近用户的那个“层”就越有优势。

明白了这个道理，函数BootAnimation::readyToRun接下来调用setLayer就不难理解了。不过参数中传入了一个数值0x40000000，这又是什么意思？其实这个值就是layer的层级，在显示系统中通常被称为Z-Order，而且数字越大就越靠近用户。后续在WindowManagerService章节的分析中，我们还会看到对setLayer的调用。BootAnimation显示时因为整个系统中还只有开机画面一个应用程序，所以并不需要担心Z-Order的问题。换句话说，0x40000000这个值足矣。

设置完层级后，readyToRun接着调用control->getSurface()来得到一个Surface对象。这就是我们前两个小节介绍的两个本地窗口中的其中一个，不清楚的读者可以回头复习一下。

涉及的相关类越来越多，相信不少人的“大脑堆栈”已经有点混乱了，因此我们有必要先来整理下目前已经出现的容易混淆的各个类的关系。

ISurfaceComposerClient：应用程序与SurfaceFlinger间的通道，在应用进程中则被封装在SurfaceComposerClient这个类中。这是一个匿名的Binder Server，由应用程序（具体位置在SurfaceComposerClient::onFirstRef中）调用SurfaceFlinger这个实名Binder的createConnection方法来获取到，服务端的实现是SurfaceFlinger::Client。

IGraphicBufferProducer：由应用程序调用ISurfaceComposerClient::createSurface()得到，同时在SurfaceFlinger这一进程中将会有一个Layer被创建，代表了一个“画面”。ISurface就是控制这一画面的handle，它将保存在应用程序端的SurfaceControl中。

Surface：从逻辑关系上看，它是上述ISurface的使用者。从继承关系上看，它是一个本地窗口。Surface内部持有IGraphicBufferProducer，即BufferQueue的实现接口。换个角度来思考，当EGL想通过Surface这个Native Window完成某些功能时，后者实际上又利用ISurface和IGraphicBufferProducer来取得远程服务端的对应服务，以完成EGL的请求。

回到BootAnimation::readyToRun()中来。因为本地窗口Surface已经成功创建，接下来就该EGL上场了。具体流程我们在代码中都加了注释，这里就不再赘述。

当EGL准备好环境后，意味着程序可以正常使用OpenGL ES提供的各种API函数进行绘图了。这部分实现就集中在随后的threadLoop()以及android()/movie()中。因为不属于本小节的讨论范围，有兴趣的读者可以自行参阅学习。

最后来做下小结，一个典型的应用程序使用SurfaceFlinger进行绘图的流程如图9-18所示（其中涉及IgraphicBufferProducer、Surface、SurfaceControl、Layer等太多元素，只选取部分重点类进行展示）。

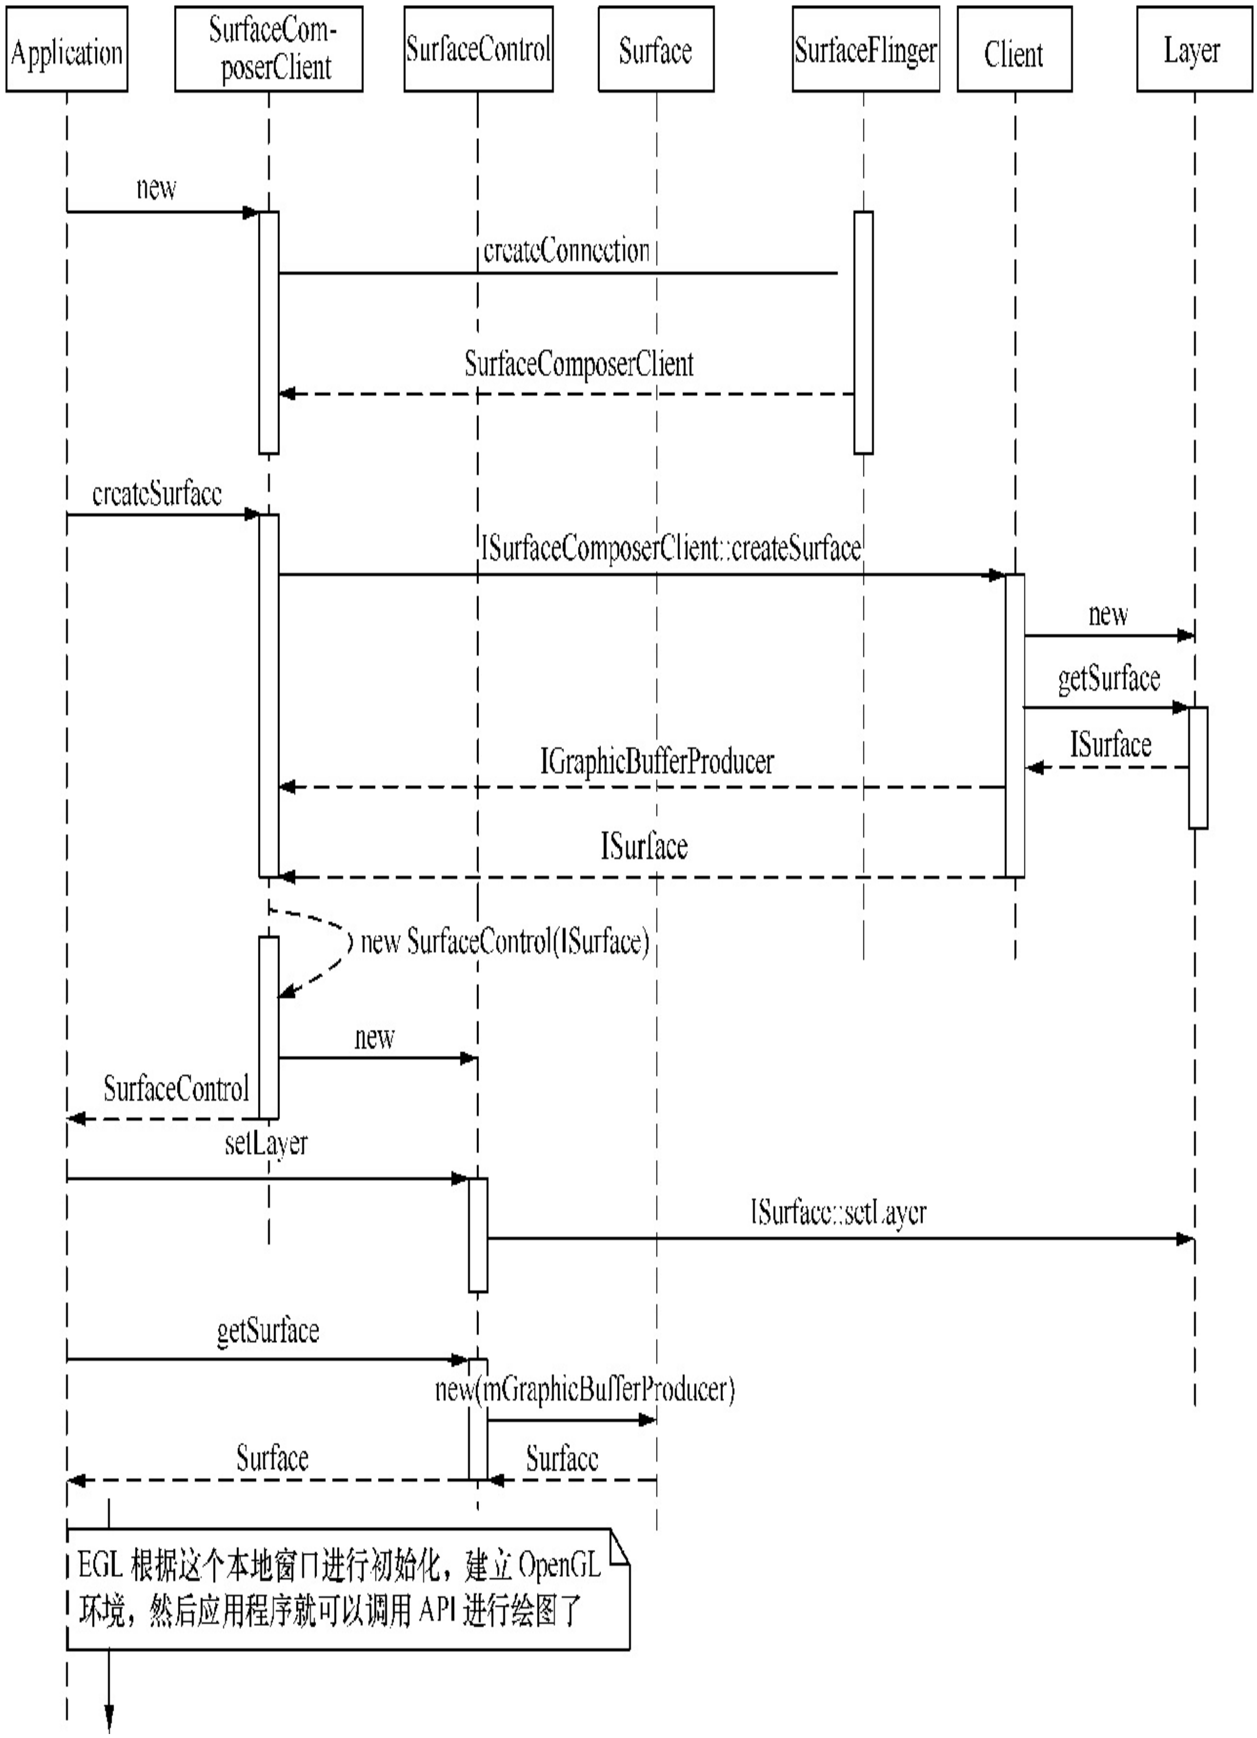

Application
SurfaceComposerClient
SurfaceControl
Surface
SurfaceFlinger
Client
Layer
new
createConnection
SurfaceComposerClient
createSurface
ISurfaceComposerClient::createSurface
new
getSurface
ISurface
IGraphicBufferProducer
ISurface
new SurfaceControl(ISurface)
new
SurfaceControl
setLayer
ISurface::setLayer
getSurface
new(mGraphicBufferProducer)
Surface
Surface
EGL 根据这个本地窗口进行初始化，建立 OpenGL 环境，然后应用程序就可以调用 API 进行绘图了

▲图9-18　应用程序通过SurfaceFlinger进行绘图的典型流程

图9-18是从时序（纵向）角度总结出来的流程，我们再从横向的角度来分析下，相信大家应该会更清楚，如图9-19所示。

从图9-19中可以看到，涉及的类还是比较多的，而且多数都涉及跨进程通信。希望大家能熟记这两张图——在后几个小节的学习中，感觉混乱时也可以回头看看，以加深印象。

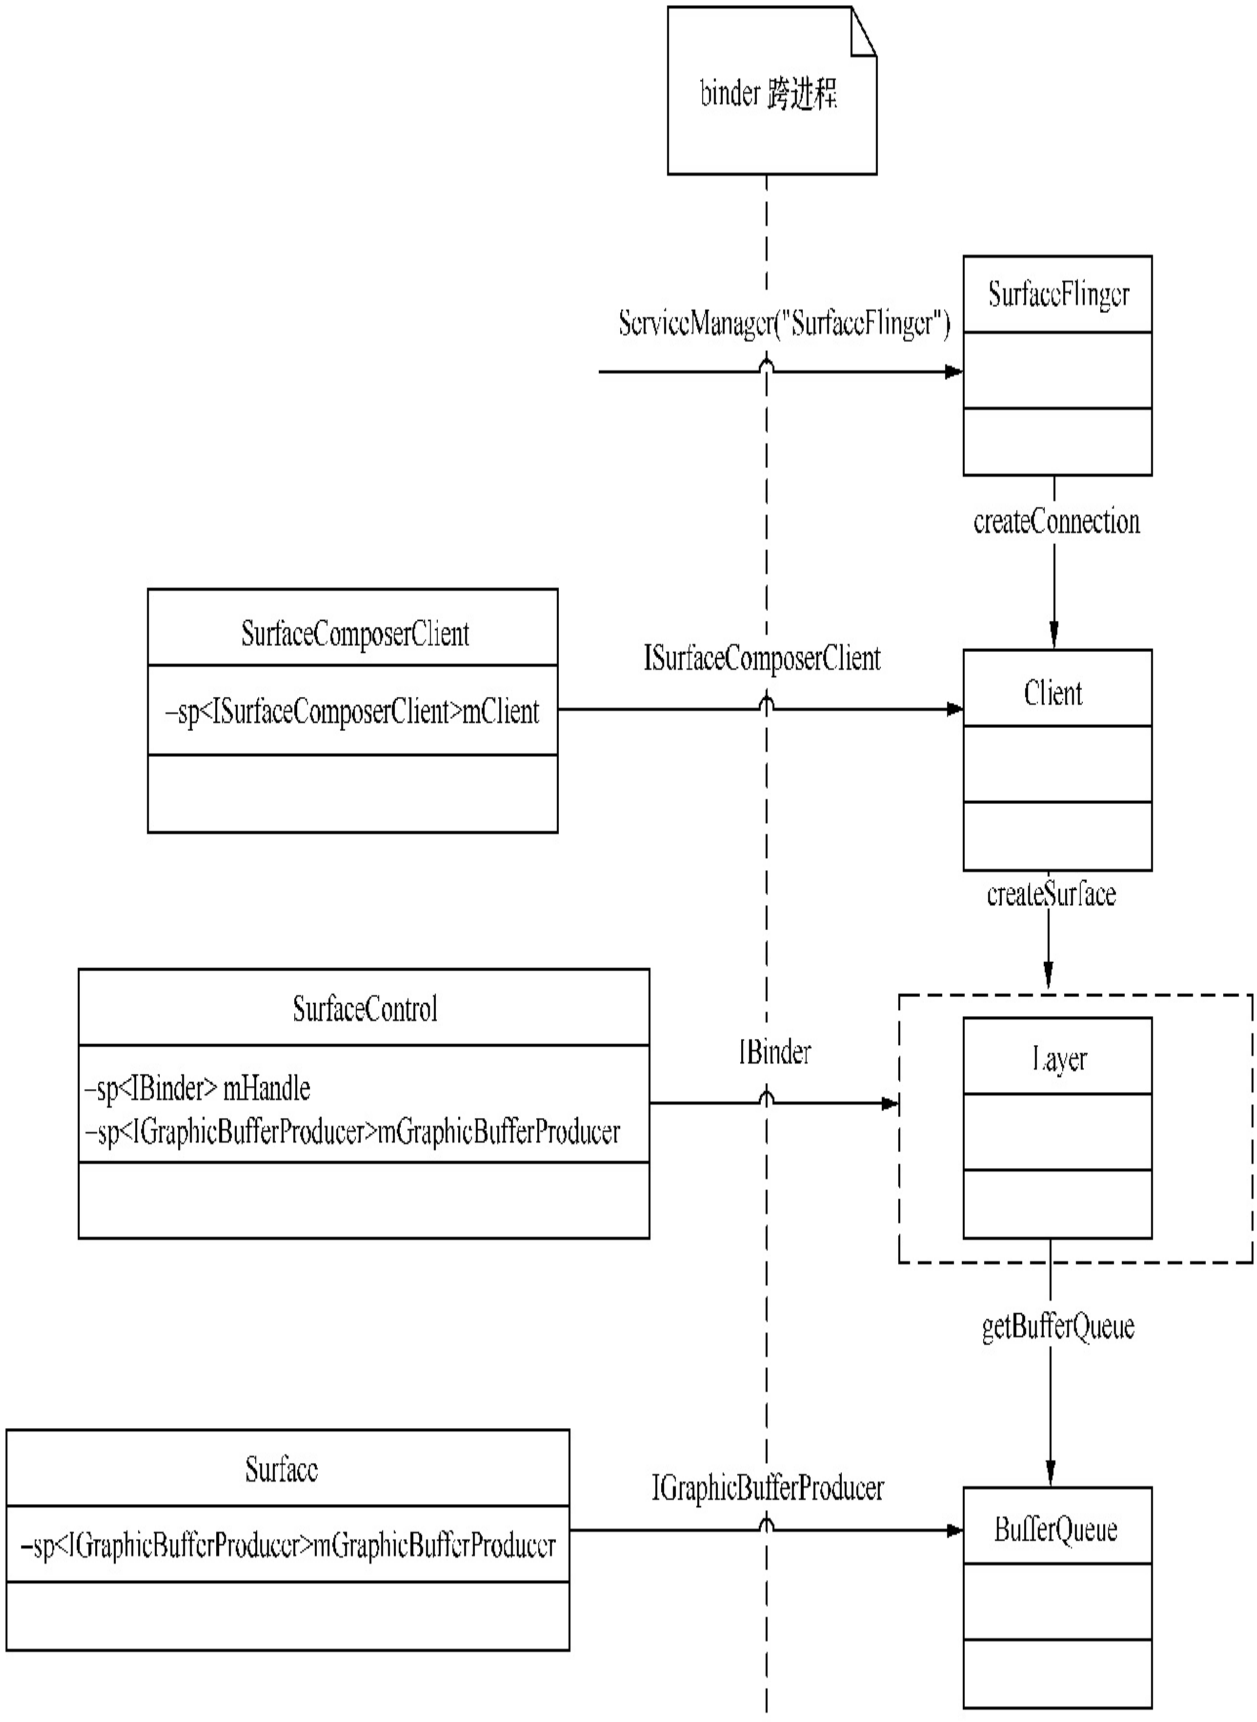
binder 跨进程
SurfaceFlinger
ServiceManager("SurfaceFlinger")
createConnection
SurfaceComposerClient
-sp<ISurfaceComposerClient>mClient
ISurfaceComposerClient
Client
createSurface
SurfaceControl
-sp<IBinder> mHandle
-sp<IGraphicBufferProducer>mGraphicBufferProducer
IBinder
Layer
getBufferQueue
Surface
-sp<IGraphicBufferProducer>mGraphicBufferProducer
IGraphicBufferProducer
BufferQueue

▲图9-19　从横向角度考查Surface相关类的关系

9.5.4　应用程序与BufferQueue的关系

接着上一小节未解决完的问题继续讲解。

现在我们已经明白了应用程序利用SurfaceFlinger进行绘制工作的大致流程，只不过在这个过程中直到最后才出现了BufferQueue。那么，应用程序具体是如何借助BufferQueue来完成工作的呢？

仔细观察不难发现，当应用程序端通过ISurfaceComposerClient::createSurface()来发起创建Surface的请求时，SurfaceFlinger服务进程这边会创建一个Layer。既然Layer代表了一个画面图层，那么它肯定需要存储“图层数据”的地方，因而我们选择以这里作为入口：

```
/*frameworks/native/services/surfaceflinger/SurfaceFlinger.cpp*/
status_t SurfaceFlinger::createLayer(const String8& name, const s
        uint32_t w, uint32_t h, PixelFormat format, uint32_t flag
        sp<IBinder>* handle, sp<IGraphicBufferProducer>* gbp)
{…
    status_t result = NO_ERROR;
    sp<Layer> layer;

    switch (flags & ISurfaceComposerClient::eFXSurfaceMask) {//La
        case ISurfaceComposerClient::eFXSurfaceNormal://普通Layer
            result = createNormalLayer(client, name, w, h, flags,
            break;
        case ISurfaceComposerClient::eFXSurfaceDim://Dim效果的Laye
            result = createDimLayer(client, name, w, h, flags, ha
            break;
        default:
            result = BAD_VALUE;
            break;
    }

    if (result == NO_ERROR) {
        addClientLayer(client, *handle, *gbp, layer);//添加到全局的
        setTransactionFlags(eTransactionNeeded);//设置业务标志
    }
    return result;
}
```

这个函数用于生成一个Layer。从enum值定义来看，当前系统中有多达十几种Layer类型，只不过多数还没有真正实现。目前能用的只有两个，即eFXSurfaceNormal和eFXSurfaceDim。第一种就是正常情况下的图层；第二种是指带有Dim效果的“图层”。顺便提一下，早前版本中还有一种Blur效果的Layer。可能出于效率的考虑，当前系统中已经统一将它用Dim替代了。

相信在后续的Android版本中还会把它们再区分开来。

最终返回给调用者的有两个：即handle和gbp。前者是一个IBinder对象，后者则是大家熟悉的IGraphicBufferProducer。

Layer和handle及gbp有什么联系呢？我们选取eFXSurfaceNormal类型的图层来深入分析：

```
status_t SurfaceFlinger::createNormalLayer(const sp<Client>& clie
        const String8& name, uint32_t w, uint32_t h, uint32_t fla
        sp<IBinder>* handle, sp<IGraphicBufferProducer>* gbp, sp<
{…//format的赋值过程省略
    *outLayer = new Layer(this, client, name, w, h, flags);//生成L
    status_t err = (*outLayer)->setBuffers(w, h, format, flags);/
    if (err == NO_ERROR) {
        *handle = (*outLayer)->getHandle();//handle是通过这个函数获耳
        *gbp = (*outLayer)->getBufferQueue();//gbp是从Layer中取出来
    }
    ALOGE_IF(err, "createNormalLayer() failed (%s)", strerror(-er
    return err;
}
```

上面这个函数的逻辑很简单：新建Layer对象，设置Buffers的属性（setBuffers），然后分别通过getHandle和getBufferQueue获得handle及gbp。

先来看看handle到底是何方“神圣”：

```
sp<IBinder> Layer::getHandle() {
    Mutex::Autolock _l(mLock);
    …
    class Handle : public BBinder, public LayerCleaner {//Handle“
    wp<const Layer> mOwner;
    public:
        Handle(const sp<SurfaceFlinger>& flinger, const sp<Layer>
            : LayerCleaner(flinger, layer), mOwner(layer) {//空的，
```

```
        }
    };
    return new Handle(mFlinger, this);//新建一个Handle对象
}
```

Android 4.1系统中有一个ISurface，功能和Handle有点类似。不过4.1版本中有很多冗余的类定义，使得整个Surface机制显得笨重而难以理解——可能是为了改善这个问题，4.3系统中已经对这些类进行了整合及移除。

由这段代码可以看出，Handle几乎没有任何有用的内容。那么，其设计初衷是什么？

仔细观察可以发现，Handle继承了LayerCleaner。从字面意思来看，它是“图层清理者”，清理时机如下所示：

```
Layer::LayerCleaner::～LayerCleaner() {
    // destroy client resources
    mFlinger->onLayerDestroyed(mLayer);
}
```

也就是说，当LayerCleaner（或者Handle）进行析构操作时，会去主动调用SurfaceFlinger的onLayerDestroyed来收拾“图层残局”。换句话说，一旦没有人引用此Handle对象，系统就会开始清理工作，是不是很方便？

了解了Handle后，我们再来分析Layer中的另一个重要元素，即BufferQueue：

```
/*frameworks/native/services/surfaceflinger/Layer.cpp*/
sp<BufferQueue> Layer::getBufferQueue() const {
    return mSurfaceFlingerConsumer->getBufferQueue();
}
```

SurfaceFlinger自认为是“Consumer”还是比较贴切的。而这个消费者的另一个职责居然是提供Buffer空间，真是“一条龙服务”。我们可以来看看SurfaceFlinger是如何提供的BufferQueue，其中又涉及多个类的继承，如图9-20所示。

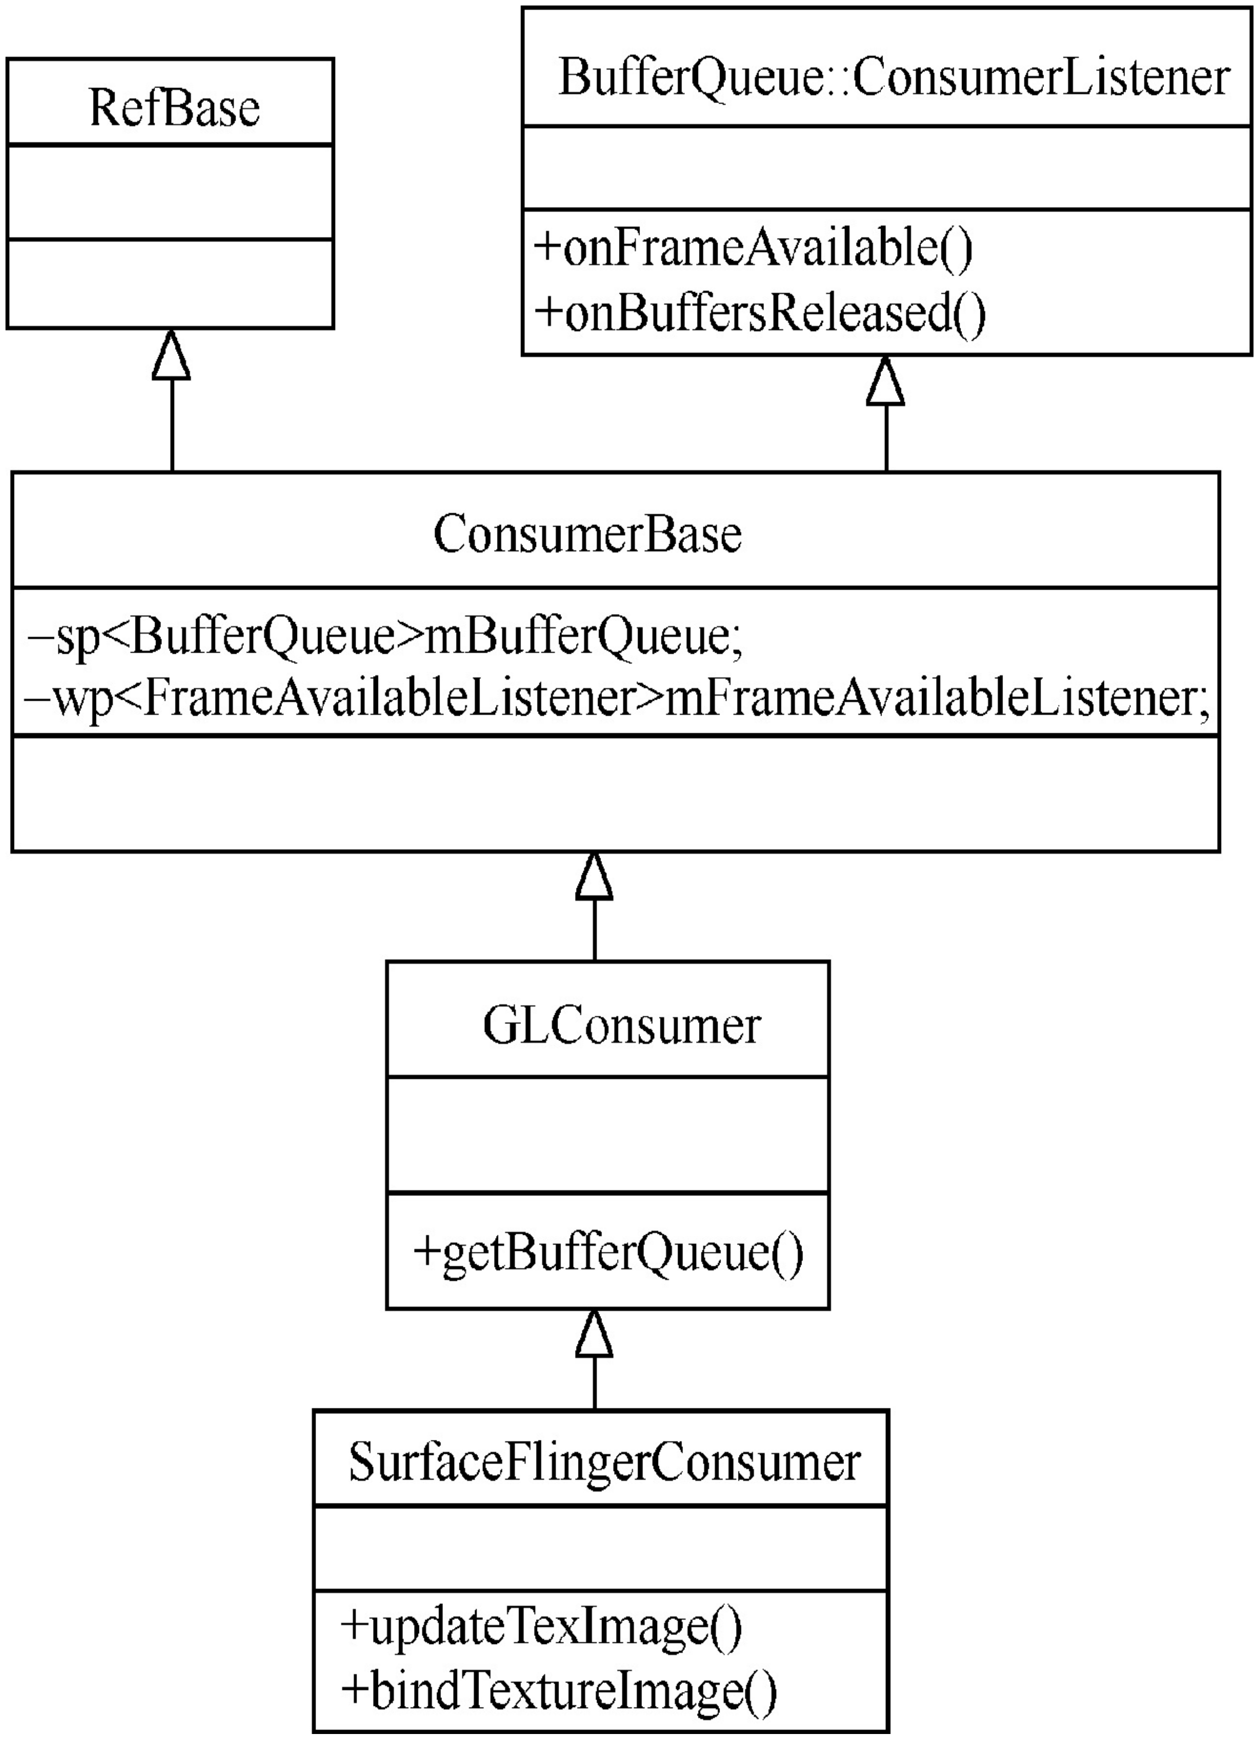

RefBase
BufferQueue::ConsumerListener
+onFrameAvailable()
+onBuffersReleased()
ConsumerBase
–sp<BufferQueue>mBufferQueue;
–wp<FrameAvailableListener>mFrameAvailableListener;
GLConsumer
+getBufferQueue()
SurfaceFlingerConsumer
+updateTexImage()
+bindTextureImage()

▲图9-20　SurfaceFlingerConsumer的继承关系

从图中可以看到，SurfaceFlingerConsumer中真正持有BufferQueue对象的是成员变量ConsumerBase::mBufferQueue，那么这个变量又是怎么赋值的呢？

其实还是在Layer中，即当有人第一次引用Layer时触发了它的onFirstRef。此时：

```
void Layer::onFirstRef()
{
    sp<BufferQueue> bq = new SurfaceTextureLayer(mFlinger);//这是什
    mSurfaceFlingerConsumer = new SurfaceFlingerConsumer(mTexture
                                                    GL_TEXTURE_EXTERN
```

又有一个新面孔出现了，即SurfaceTextureLayer，很显然它应该是BufferQueue的子类。有兴趣的读者可以自行研究下其在BufferQueue的基础上提供了哪些新功能。

这样就基本清楚了，Layer中直接或者间接地提供了Handle和BufferQueue，而且两者都是匿名的Binder Server。当客户端应用程序调用createSurface时，它可以同时获取到这两个重要对象。大家一定要记住，IGraphicBufferProducer的Server端的实现是BufferQueue。由于命名上的差异，这点很容易搞错。

因而应用程序与BufferQueue的关系就比较明朗了。虽然中间经历了多次跨进程通信，但对于应用程序来说最终只使用到了BufferQueue（通过IGraphicBufferProducer）。

本小节可以从侧面证明如下几个关键点。

（1）应用程序可以调用createSurface来建立多个Layer，它们是一对多的关系。理由就是createSurface中没有任何机制来限制应用程序的多次调用；相反，它会对一个应用程序多次申请而产生的Layer进行统一管理。如下所示：

```
status_t SurfaceFlinger::createLayer(…)
{…
    if (result == NO_ERROR) {
```

```
    addClientLayer(client, *handle, *gbp, layer);//添加新增的Layer到
    setTransactionFlags(eTransactionNeeded);
    }
```

为应用程序申请的Layer，一方面需要告知SurfaceFlinger，另一方面要记录到各Client内部中。这两个步骤是由addClientLayer()分别调用Client::attachLayer()和SurfaceFlinger::addLayer_l()来完成的：

```
void SurfaceFlinger::addClientLayer(const sp<Client>& client,cons
        const sp<IGraphicBufferProducer>& gbc,const sp<Layer>& lb
{
    // attach this layer to the client
    client->attachLayer(handle, lbc);//让此Layer与Client相关联

    // add this layer to the current state list
    Mutex::Autolock _l(mStateLock);
    mCurrentState.layersSortedByZ.add(lbc);//将Layer按顺序添加到全局
    mGraphicBufferProducerList.add(gbc->asBinder());//将gbc也添加到
}
```

对于SurfaceFlinger，它需要对系统中当前所有的Layer进行Z-Order排序，以决定用户所能看到的“画面”是什么样的；对于Client，它则利用内部的mLayers成员变量来逐一记录新增（attachLayer）和移除（detachLayer）的图层。从中不难看出，一个Client是可以包含多个Layer的。

（2）每个Layer对应一个BufferQueue。换句话说，一个应用程序可能对应多个BufferQueue。另外，Layer没有直接持有BufferQueue对象，而是由其内部的mSurfaceFlingerConsumer来管理。

我们以图9-21来结束本小节的学习。

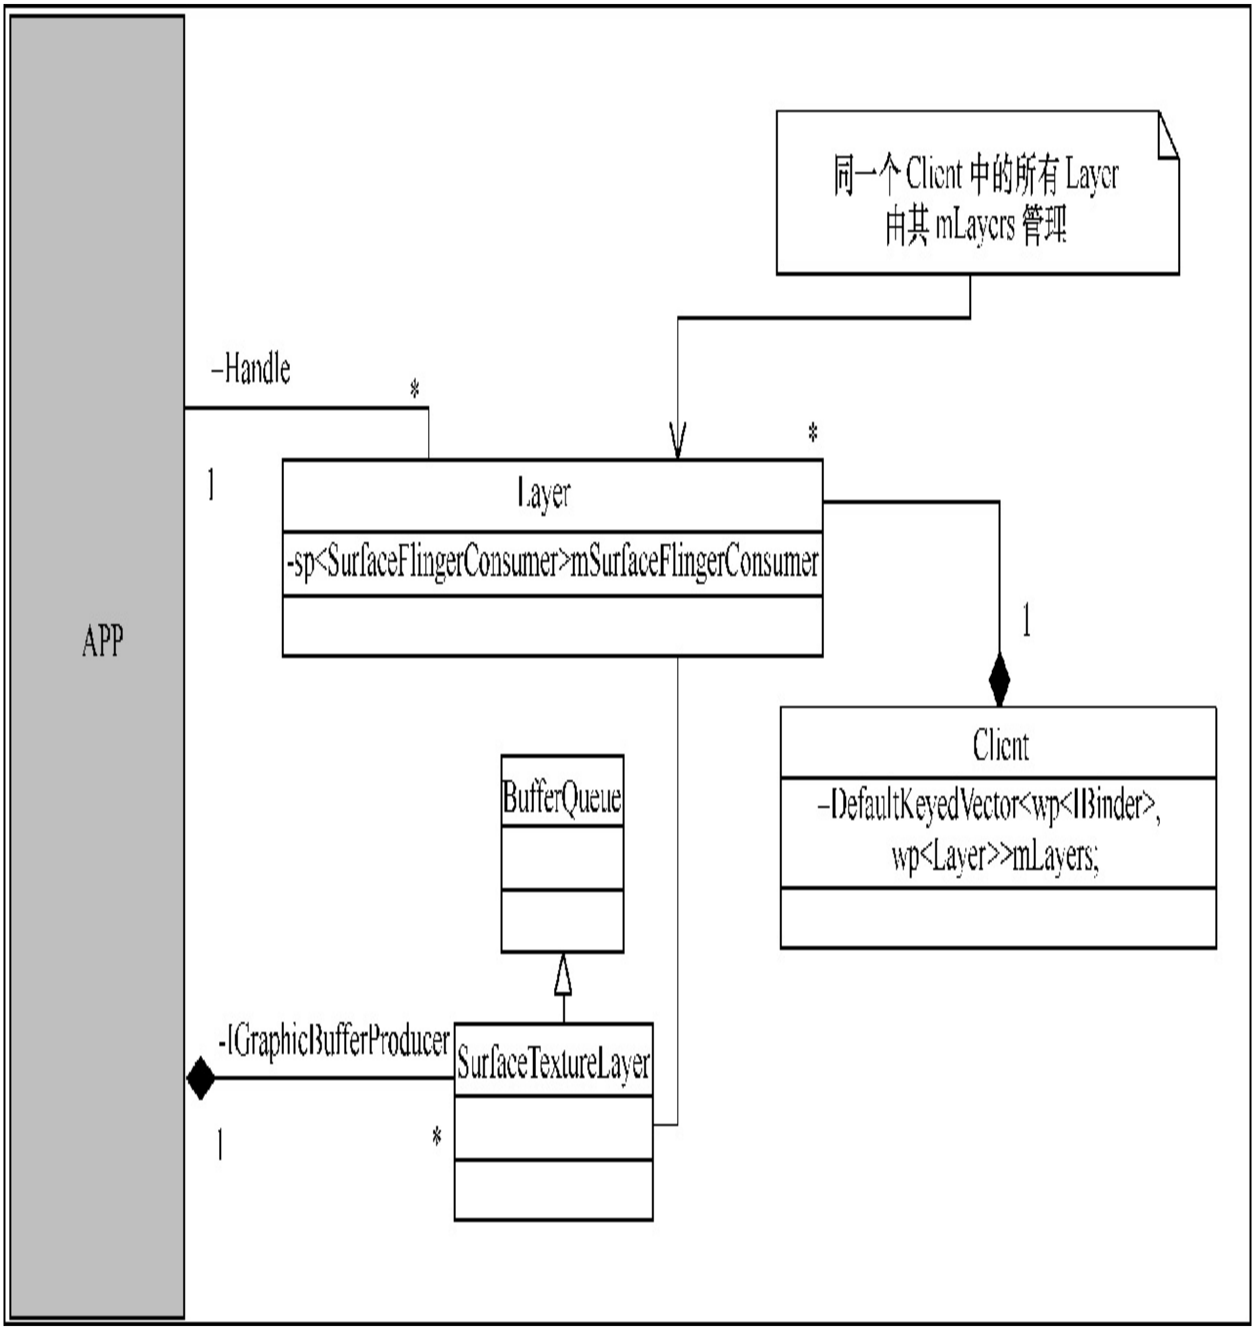

▲图9-21　应用程序与BufferQueue的对应关系

9.6 SurfaceFlinger

从本小节开始，我们正式切入SurfaceFlinger的分析。为了保持讲解的连贯性，部分内容可能在前面的章节中已经有所涉及，接下来将会对其中的细节做更多的扩展讲解。

内容组织如下。

- 首先介绍从Android 4.1版本起引入的一个新特性（Project Butter）。理解这个项目是必要的，可以说SurfaceFlinger有很大一部分内容就是围绕它展开的。
- SurfaceFlinger的启动过程及工作方式。
- SurfaceFlinger与BufferQueue及应用程序间的关系。
- SurfaceFlinger对VSYNC信号的处理过程（重点）。

9.6.1 “黄油计划”——Project Butter

为什么会叫这个名字呢？一个可能的原因就是这个Project的目的是改善用户抱怨最多的Android几大缺陷之一，即UI响应速度——Google希望这一新计划可以让Android系统摆脱“UI交互”上的“滞后”感，而能像加了黄油一般“顺滑”。Google在2012年的I/O大会上宣布了这一计划，并在Android 4.1中正式搭载了具体的实现机制。

Butter中有两个重要的组成部分，即VSync和Triple Buffering。下面先分别介绍引入它们的原因。

喜欢玩游戏或者看电影的读者可能经常遇到以下情形。

- 某些游戏场面好像由几个场景“拼凑”而成。
- 电影画面不连贯，好像被“割裂”了。

这样描述有点抽象，我们引用wikipedia上的一张图来看下实际效果，如图9-22所示。

我们把这种显示错误称为“Screen Tearing”，那么为什么会出现

这样的情况呢？

相信大家都能得出结论，那就是屏幕上显示的画面实际上来源于多个“帧”。

在一个典型的显示系统中，Frame Buffer代表了屏幕即将要显示的一帧画面。假如CPU/GPU绘图过程与屏幕刷新所使用的buffer是同一块，那么当它们的速度不同步的时候，则很可能出现类似的画面“割裂”。举个具体的例子，假设显示器的刷新率为66Hz，而CPU/GPU的绘图能力则达到100Hz，也就是它们处理完成一帧数据分别需要0.015秒和0.01秒。

▲图9-22　Screen Tearing实例 {-:-}注：引自
http://en.wikipedia.org/wiki/File:Tearing_%28simulated%29.jpg。

以时间为横坐标来描述接下来会发生的事情，如图9-23所示。

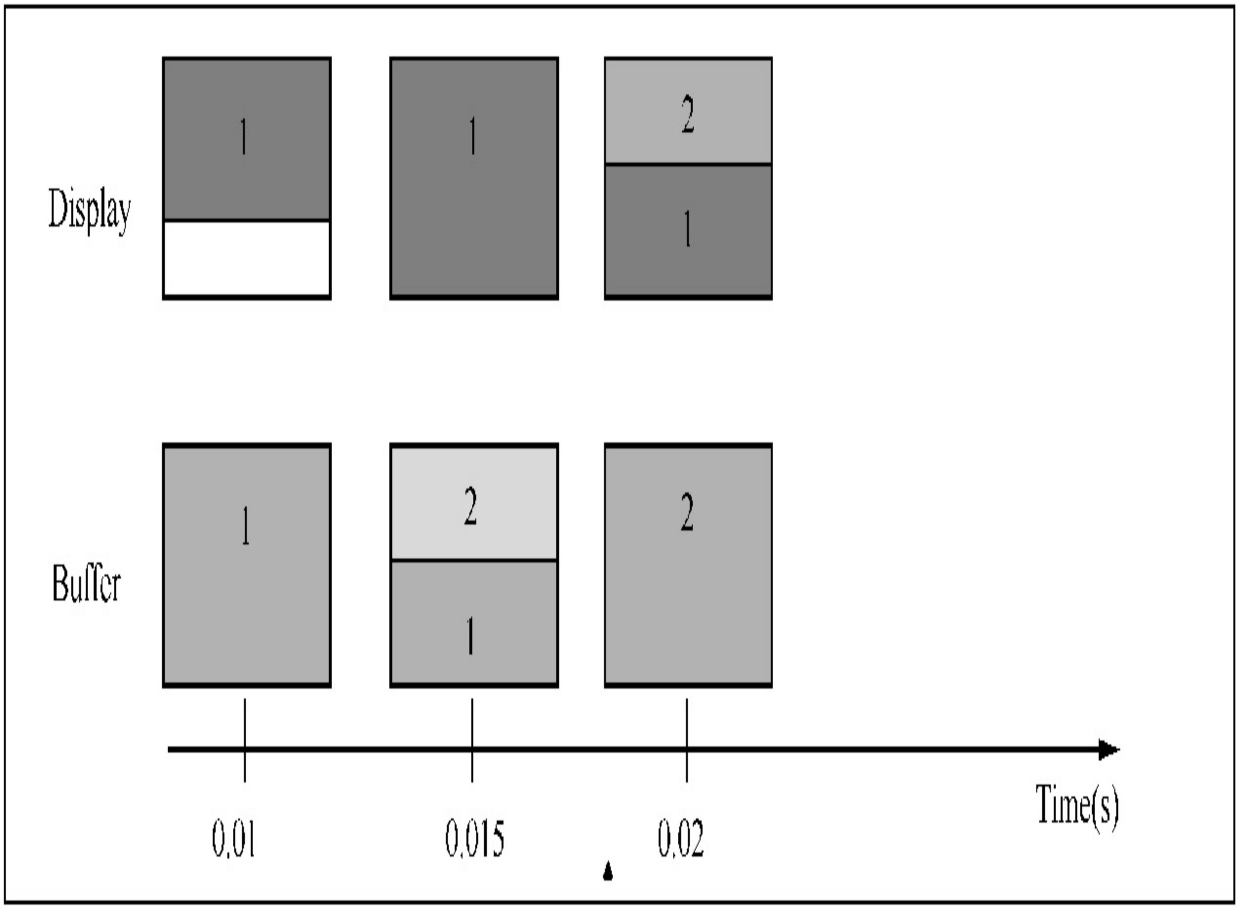

▲图9-23　Screen Tearing产生过程分析

上半部分的方框表示在不同的时间点时显示屏的内容（加深的部分），下半部分则是同一时间点时Frame Buffer中的数据状态，编号表示第几个frame帧，不考虑清屏。

- 0.01秒

由于两者速率相差不少，此时buffer中已经准备好了第1帧数据，而显示器只显示了第1帧画面的2/3。

- 0.015秒

第1帧画面在显示屏上终于完整地显示了出来，而此时buffer中有1/3的部分已经被填充上第2帧数据了。

- 0.02秒

Buffer中已经准备好了第2帧数据，而显示屏出现了Screen Tearing：有三分之一的内容属于第2帧，其余的则来源于第1帧画面。

在单缓冲区的情况下，这个问题是很难规避的。所以之前我们介绍的双缓冲技术，其基本原理就是采用了两块buffer——其中一块Back Buffer用于CPU/GPU后台绘制，另一块Frame Buffer则用于屏幕显示；当Back Buffer准备就绪后，它们才进行交换。不可否认，Double Buffering可以在很大程度上降低Screen Tearing类型的错误，但它是万能的吗？

一个需要考虑的问题是：我们应该每隔多少时间点进行两个缓冲区的交换呢？假如是Back Buffer准备完成一帧数据以后就进行，那么如果此时屏幕还没有完整显示上一帧内容，肯定是会出问题的。看来只能等到屏幕处理完一帧数据后，才可以执行这一操作。

我们知道，一个典型的显示器有两个重要特性，即“行频和场频”。行频（Horizontal Scanning Frequency）又称为“水平扫描频率”，是屏幕每秒钟从左至右扫描的次数；场频（Vertical Scanning Frequency）也称为“垂直扫描频率”，是每秒钟整个屏幕刷新的次数。由此也可以得出它们的关系：行频=场频*纵坐标分辨率。

当扫描完一个屏幕后，设备需要重新回到第一行以进入下一轮的循环，此时有一段时间空隙，称为Vertical Blanking Interval(VBI)。大家应该能想到，这个时间点就是我们进行缓冲区交换的最佳时间。因为此时屏幕没有在刷新，也就避免了交换过程中出现Screen Tearing的状况。Vsync（垂直同步）是Vertical Synchronization的简写，它利用VBI时期出现的Vertical Sync Pulse来保证双缓冲能在最佳时间点进行交换。

所以说VSync这个概念并不是Google首创的，而是在早些年前的PC领域就已经出现了。不过Android 4.1赋予了它新的功用，稍后就可以看到。

上面我们讨论的情况其实是基于一个假设，即绘图速度大于显示速度，那么如果反过来呢？绘图过程中没有采用VSync同步时如图9-24所示。

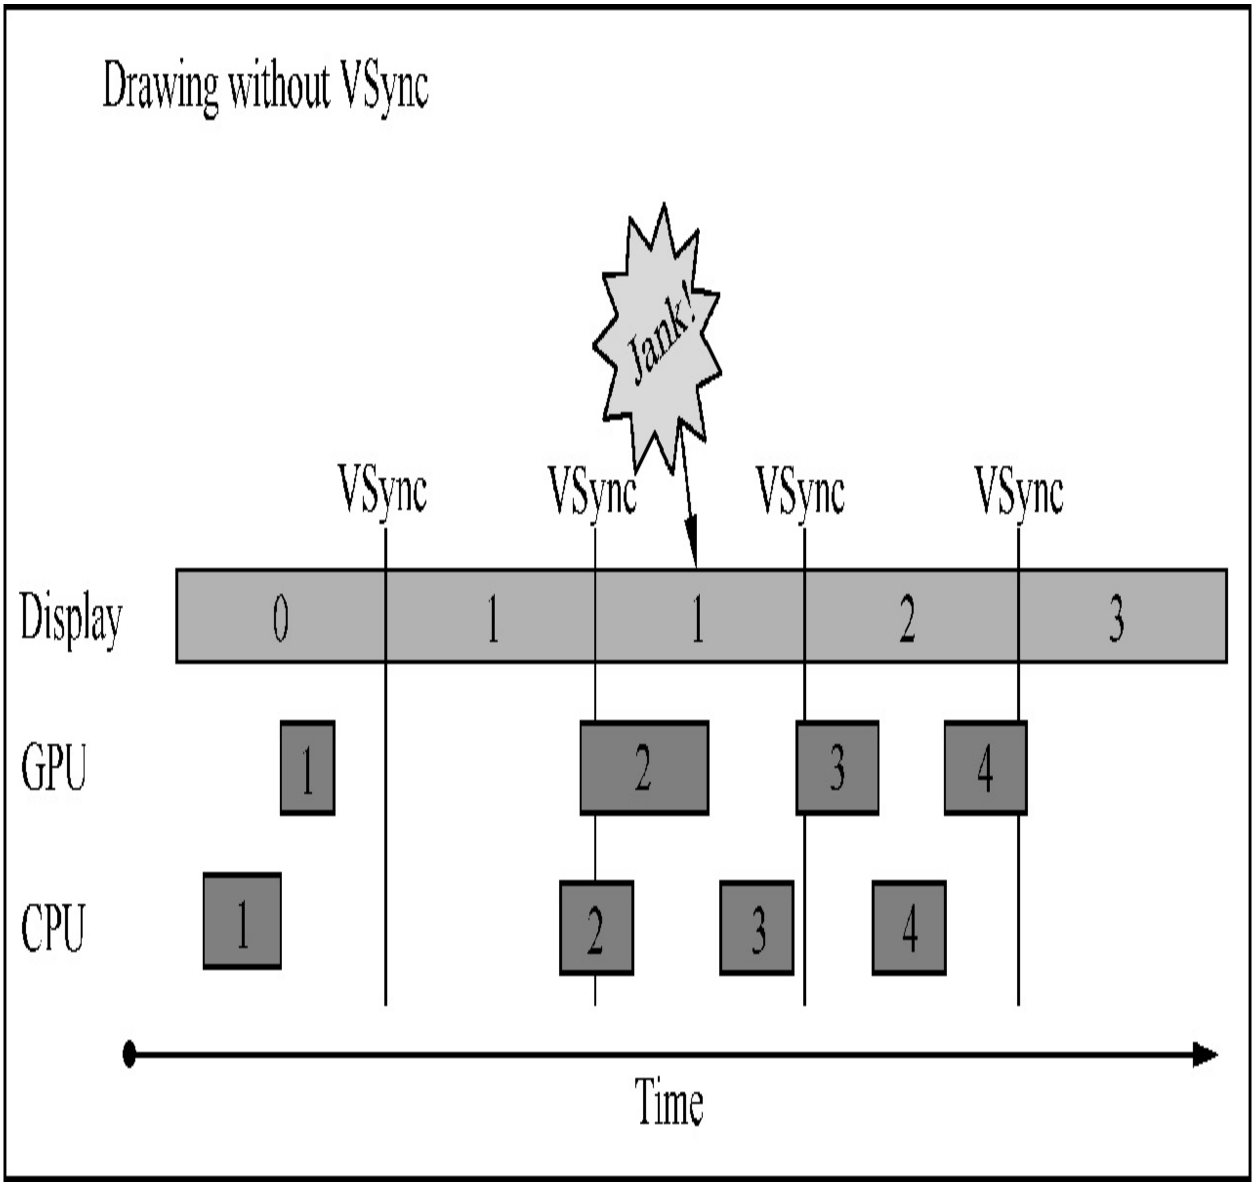

▲图9-24　绘图过程中没有采用VSync同步的情况

此图和后续几张图均引用自Google 2012 I/O大会的主题演讲，作者是Chet Haase和Romain Guy(Android UI Toolkit Engineers)。

图9-24中有3个元素，Display表示显示屏幕，GPU和CPU负责渲染帧数据。每一帧以方框表示并以数字进行编号，如0、1、2等。VSync用于指导双缓冲区的交换。

以时间的顺序来看看当不采用VSync同步时将会发生什么异常。

Step1. Display显示第0帧数据，此时CPU和GPU渲染第1帧画面，而且赶在Display显示下一帧（帧1）前完成。

Step2. 因为渲染及时，Display在第0帧显示完成后，也就是第1个VSync后，正常显示第1帧。

Step3. 由于某些原因（比如CPU资源被占用），系统没能及时地处理第2帧，而是等到第2个VSync到来前才开始处理。

Step4. 第2个VSync来临时，由于第2帧数据还没有准备就绪，实际显示的还是第1帧的内容。这种情况被Android开发组命名为“Jank”。

Step5. 当第2帧数据准备完成后，它并不会立即被显示，而是要等待下一个VSync。

所以总的来说，就是屏幕“平白无故”地重复显示了一次第1帧。原因大家应该都看到了，就是CPU没有及时地着手处理第2帧的渲染工作，以致“延误军机”。Android系统中一直存在着这个问题，直到Project Butter的引入。

从Android 4.1 Jelly Bean开始，VSync得到了进一步的应用——系统在收到VSync Pulse后，将立即开始下一帧的渲染，如图9-25所示。

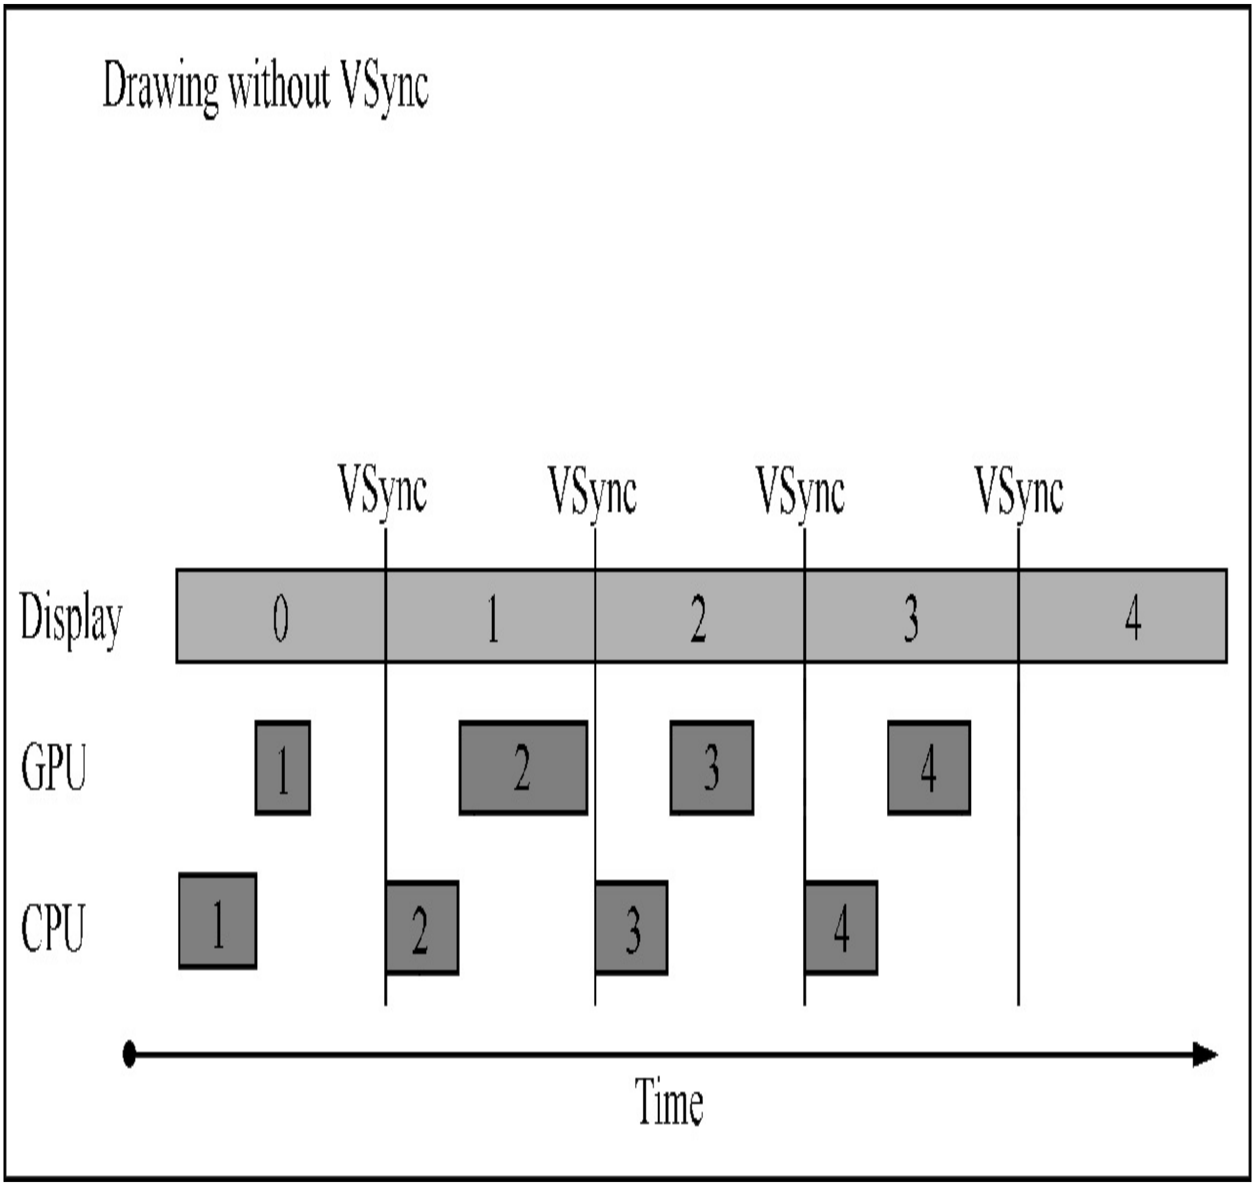

▲图9-25　整个显示系统都以VSync进行同步的情况

图中展示的是采用VSync进行显示同步的情况。一旦VSync信号出现，CPU便不再犹豫，即刻开始执行Buffer的准备工作。大部分的Android显示设备刷新频率是60Hz，这也就意味着每一帧最多只能留给系统1/60=16ms左右的准备时间。假如CPU/GPU的FPS(Frames Per Second)高于这个值，那么这个方案是完美的，显示效果将很好。

可是我们没有办法保证所有设备的硬件配置都能达到要求。假如CPU/GPU的性能无法满足上图条件，又会是什么情况呢？

在分析这一问题之前，我们先来看看采用双缓冲区系统的运行情况，如图9-26所示。

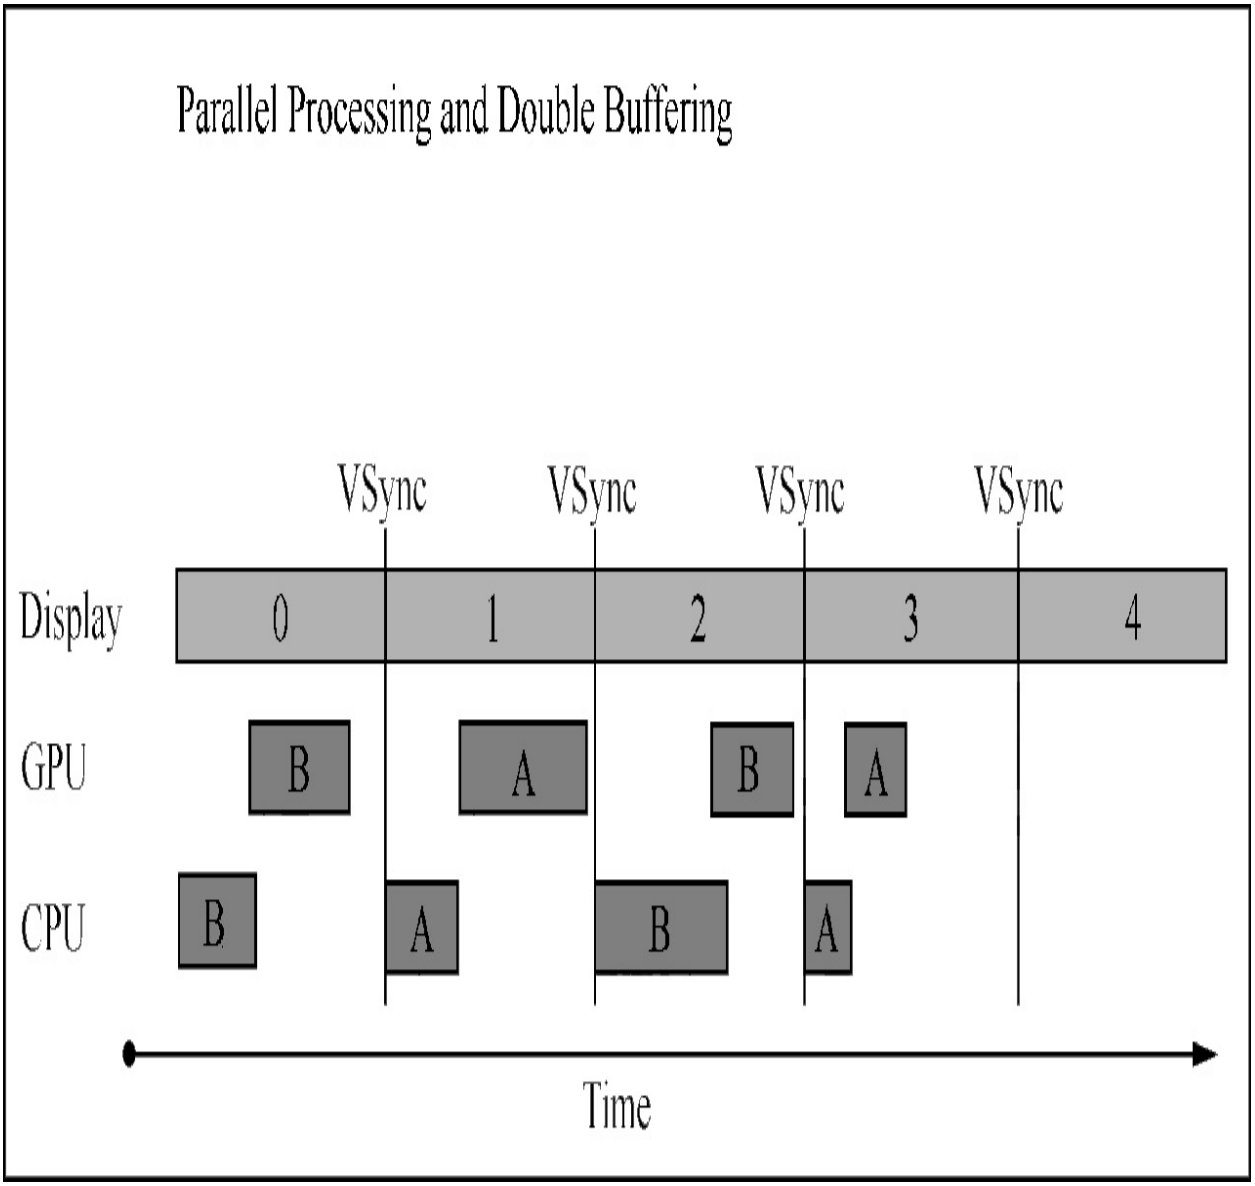

▲图9-26　采用VSync和双缓冲机制的情况

图中采用了双缓冲技术以及前面介绍的VSync同步机制，可以看到整个显示过程还是相当不错的。虽然CPU/GPU处理所用的时间时短时长，但总的来说都在16ms以内，因而不影响显示效果。A和B分别代表两个缓冲区，它们不断地互相交换以保证画面的正确显示。

现在我们可以继续分析FPS低于屏幕刷新率的情况了，如图9-27所

示。

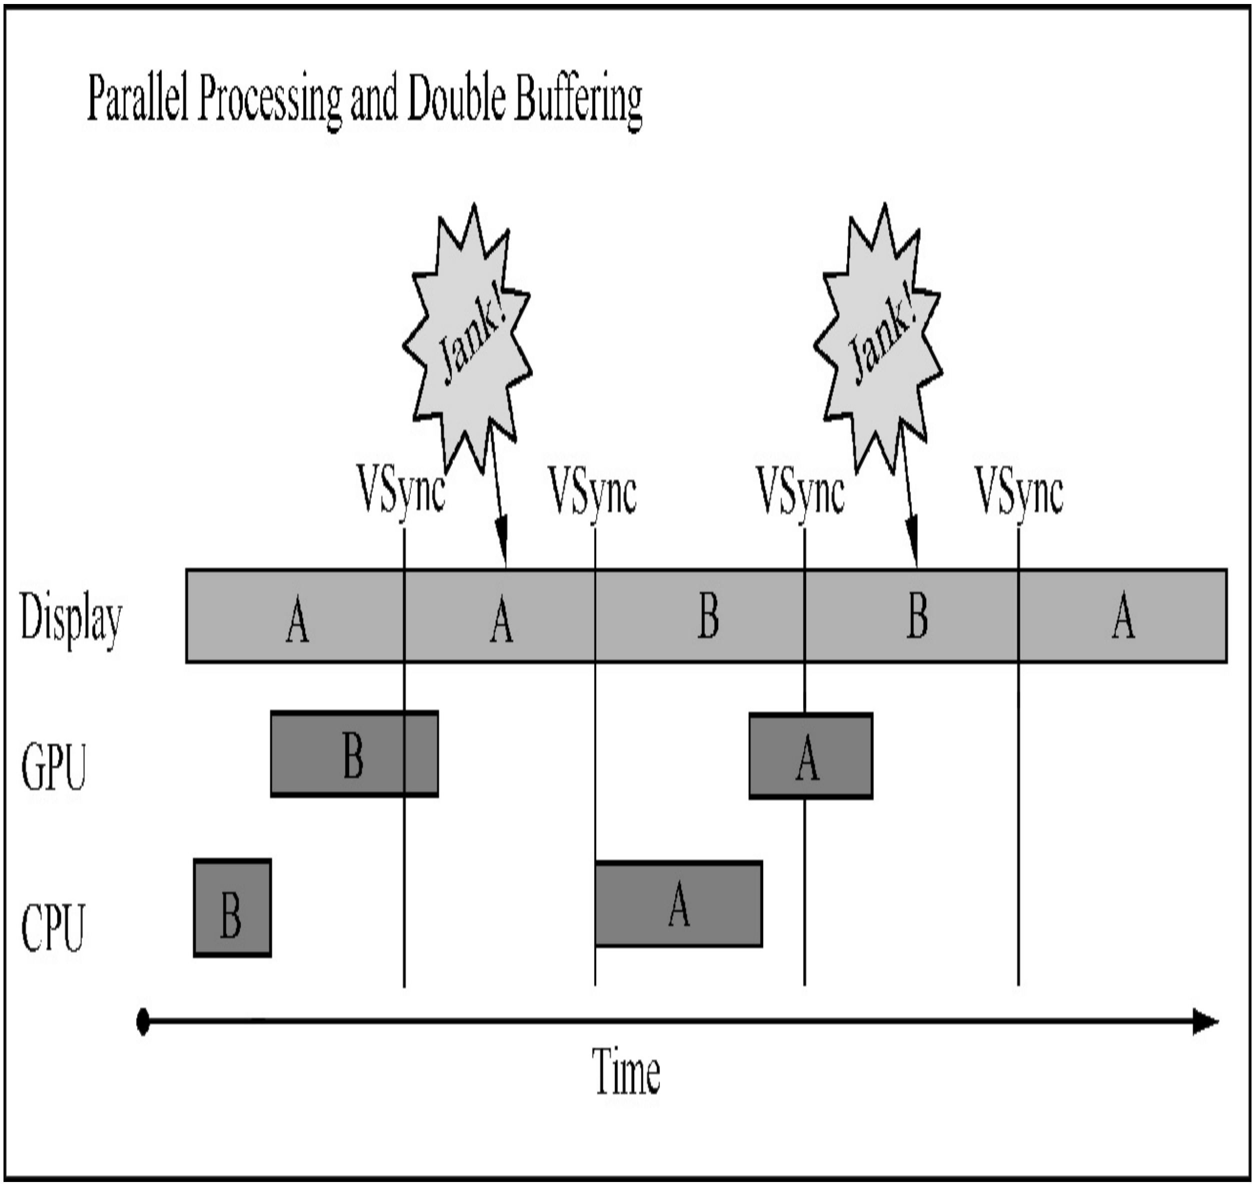

▲图9-27　FPS低于屏幕刷新率的情况

如果CPU/GPU的处理时间超过16ms，那么第一个VSync到来时，缓冲区B中的数据还没有准备好，就只能继续显示之前A缓冲区中的内容。而B完成后，又因为缺乏VSync Pulse信号，也只能等到下一轮才有机会交换了。于是在这一过程中，有一大段时间是被浪费的。当下一个VSync出现时，CPU/GPU马上执行操作，此时它可操作的Buffer是A，相应的显示屏对应的就是B。这时看起来就是正常的。只不过由于执行时间仍然超过16ms，导致下一次应该执行的缓冲区交换又被推迟——如此循环反

复，便出现了越来越多的“Jank”。

那么，有没有规避的办法呢？

很显然，第一次的Jank看起来是没有办法的，除非升级硬件配置来加快FPS。我们关注的重点是被CPU/GPU浪费的时间段怎么才能充分利用起来。分析上述过程，造成CPU/GPU无事可做的假象是因为当前已经没有可用的buffer了。换句话说，如果增加一个Buffer，情况会不会好转呢？如图9-28所示。

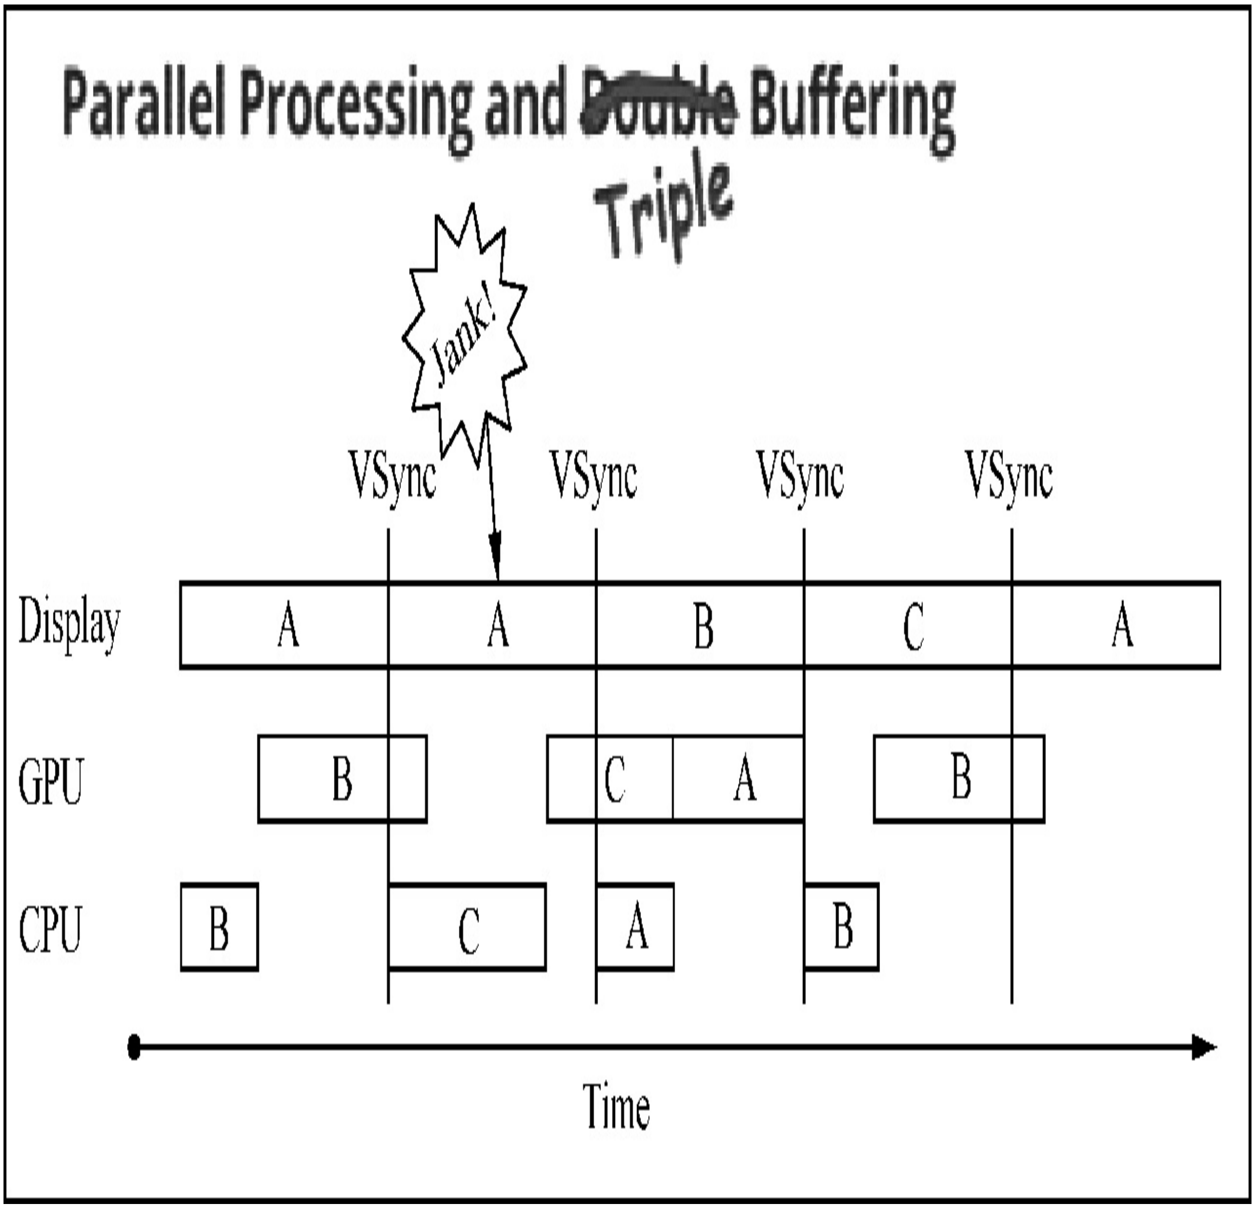

▲图9-28　Triple Buffering

Triple Buffering是Multiple Buffering的一种，指的是系统使用3个缓冲区用于显示工作。我们逐步分析下这个新机制是否有效。首先和预料中的一致，第一次“Jank”无可厚非。不过让人欣慰的是，当第一次VSync发生后，CPU不用再等待了，它会使用第三个Buffer C来进行下一帧数据的准备工作。虽然对缓冲区C的处理所需时间同样超过了16ms，但这并不影响最终的显示——第二次VSync到来后，它选择Buffer B进行显示；而到了第三次VSync时，它会接着采用C，而不是像Double Buffering中所看到的只能再显示一遍B。这样就有效地降低了系统显示错误的概率。

前面小节我们看到BufferQueue中最多有32个BufferSlot，不过在实际使用时的具体值是可以设置的。

- TARGET_DISABLE_TRIPLE_BUFFERING

这个宏用于Disable Triple Buffering。如果宏打开的话，Layer.cpp在onFirstRef有如下操作。

```
#ifdef TARGET_DISABLE_TRIPLE_BUFFERING
#warning "disabling triple buffering"
    mSurfaceFlingerConsumer->setDefaultMaxBufferCount(2);
#else
    mSurfaceFlingerConsumer->setDefaultMaxBufferCount(3);
#endif
```

mSurfaceFlingerConsumer::setDefaultMaxBufferCount将进一步调用BufferQueue::setDefault MaxBufferCount，然后把Buffer数（2或者3）保存到BufferQueue内部的mDefaultMaxBufferCount成员变量中。

- 对于应用程序来说，它也可以通过IGraphicBufferProducer::setBufferCount来告诉BufferQueue它所希望的Slot值——这个操作最终影响的是BufferQueue中的另一个成员变量mOverride MaxBufferCount（而不是mDefaultMaxBufferCount）。默认情况下这个变量是0，表示应用端不关心到底有多少Buffer可用。
- 在具体的实现中，以上两个变量都是要考虑到的，BufferQueue会通

过权衡各个值来选择最佳的解决方案。

请大家务必结合本小节分析的几种情况，理解清楚Android系统引入Triple Buffering，VSync机制的原因。只有带着这些理解进入SurfaceFlinger的分析中，才能让大家的学习“有的放矢”，对源码的剖析过程也才能“事半功倍”。

9.6.2 SurfaceFlinger的启动

SurfaceFlinger的启动和ServiceManager有点类似，它们都属于系统的底层支撑服务，因而必须在设备开机的早期就运行起来：

```
/*frameworks/base/cmds/system_server/library/System_init.cpp*/
extern "C" status_t system_init()
{…
    property_get("system_init.startsurfaceflinger", propBuf, "1")
    if (strcmp(propBuf, "1") == 0) {
        SurfaceFlinger::instantiate();
}…
```

这个System_init.cpp会被编译到libsystem_server库中，然后由SystemServer在JNI层进行加载调用，从而启动包括SurfaceFlinger，SensorService等在内的系统服务。

和我们将会在后续AudioFlinger/AudioPolicyService章节看到的情况一样，system_init调用instantiate来创建一个Binder Server，名称为“SurfaceFlinger”；而且强指针的特性让它在第一次被引用时触发了onFirstRef：

```
void SurfaceFlinger::onFirstRef()
{
    mEventQueue.init(this);//初始化事件队列
    run("SurfaceFlinger", PRIORITY_URGENT_DISPLAY);//启动一个新的业
    mReadyToRunBarrier.wait();//等待新线程启动完毕
}
```

成员变量mEventQueue是一个MessageQueue类型的对象，我们在进程章节已经详细分析过消息队列与Looper，Handler等类的使用，大家可以先回头参考下（虽然Java层的这些类与SurfaceFlinger中用到的有一定差异，但其本质原理是一样的）。既然有消息队列，那就一定会有配套的事件处理器Handler以及循环体Looper，这些是在

MessageQueue::init函数中创建的。即：

```
/*frameworks/native/services/surfaceflinger/MessageQueue.cpp*/
void MessageQueue::init(const sp<SurfaceFlinger>& flinger)
{
    mFlinger = flinger;
    mLooper = new Looper(true);
    mHandler = new Handler(*this);//此Handler类是SurfaceFlinger自己
}
```

也就是说，这个MessageQueue类不但提供了消息队列，其内部还囊括了消息的处理机制，可谓一个“大杂烩”。那么，这个Looper会在什么时候运行起来呢？显然SurfaceFlinger需要先自行创建一个新的线程来承载这一“业务”，否则就会阻塞SystemServer的主线程，这一点和AudioFlinger是有区别的。函数最后的mReadyToRunBarrier.wait()也可以证明这一点——mReadyTo RunBarrier在等待一个事件，在事件没有发生前其所在的线程就会处于等待状态。这是Android系统里两个线程间的一种典型交互方式。举个例子，A线程将启动B线程，并且A接下来的工作会依赖于B。换句话说，A必须要等到B说“好了，我已经OK”了才能继续往下走，否则就会出错。由此可见，SurfaceFlinger新启动的这个线程中一定还会调用mReadyToRunBarrier. open来为等待它的线程解禁。

这样我们也能推断出SurfaceFlinger一定是继承自Thread线程类的。如下所示：

```
class SurfaceFlinger :public BinderService<SurfaceFlinger>,
        …
private Thread,
```

所以上面SurfaceFlinger::onFirstRef函数中可以调用Thread::run()方法来启动一个名为“SurfaceFlinger”的线程，并为其设置了PRIORITY_URGENT_DISPLAY的优先级。这个优先级是在ThreadDefs.h中定义的，如表9-6所示。

数值越大的，优先级越小。因为各等级间的数值并不是连续的，所以我们还可以通过表中最后的ANDROID_PRIORITY_MORE_FAVORABLE(-1)来适当地提高优先级；或者利用ANDROID_PRIORITY_LESS_FAVORABLE(+1)来降低优先级。

表9-6　Android系统的线程优先级定义

Priority	Value	Descr
ANDROID_PRIORITY_LOWEST	19	最低优先级
ANDROID_PRIORITY_BACKGROUND	10	用于Background Ta
ANDROID_PRIORITY_NORMAL	0	大部分线程都以这
ANDROID_PRIORITY_FOREGROUND	-2	用户正在交互线程
ANDROID_PRIORITY_DISPLAY	-4	UI主线程优先级
ANDROID_PRIORITY_URGENT_DISPLAY	-8	这个值由 HAL_PRIORITY_U 来指定，当前版本 紧急状态下使用
ANDROID_PRIORITY_AUDIO	-16	正常情况下的声音
ANDROID_PRIORITY_URGENT_AUDIO	-19	紧急声音线程优先 使用）
ANDROID_PRIORITY_HIGHEST	-20	最高优先级，禁止
		默认情况下就是

ANDROID_PRIORITY_DEFAULT	0	ANDROID_PRIORI
ANDROID_PRIORITY_MORE_FAVORABLE	-1	在上述各优先级定 适当微调（加大）(
ANDROID_PRIORITY_LESS_FAVORABLE	+1	在上述各优先级定 适当微调（减小）(

由此可见，SurfaceFlinger工作线程所采用的优先级相对较高。这样做是必然的，因为屏幕UI显示无疑是人机交互中与用户体验关联最直接的，任何滞后的响应速度都将大大降低产品的吸引力。

在执行了run()以后，Thread会自动调用threadLoop()接口。即：

```
bool SurfaceFlinger::threadLoop()
{
    waitForEvent();
    return true;
}
```

相当简洁的两句话，却涵盖了所有SurfaceFlinger接下来要执行的工作。其中waitForEvent()是SurfaceFlinger中的成员函数，它会进一步调用mEventQueue.waitMessage()：

```
void MessageQueue::waitMessage() {
    do {
        IPCThreadState::self()->flushCommands();
        int32_t ret = mLooper->pollOnce(-1);
        switch (ret) {
            case ALOOPER_POLL_WAKE:
            case ALOOPER_POLL_CALLBACK:
                continue;
            case ALOOPER_POLL_ERROR:
                ALOGE("ALOOPER_POLL_ERROR");
            case ALOOPER_POLL_TIMEOUT:
                // timeout (should not happen)
                continue;
            default:
```

```
                // should not happen
                ALOGE("Looper::pollOnce() returned unknown status
                continue;
        }
    } while (true);
}
```

可以看到程序在这里进入了一个死循环，而且即便pollOnce的执行结果是ALOOPER_POLL_TIMEOUT，也同样不会跳出循环。这是Android在对待严重错误时的一种普遍态度——如果不幸发生致命错误，就听天由命吧。

下面这句代码将在内部调用MessageQueue::mHandler来处理消息：

```
mLooper->pollOnce(-1);
```

注意

pollOnce函数同样使用了一个死循环，它不断地读取消息进行处理，关系如图9-29所示。

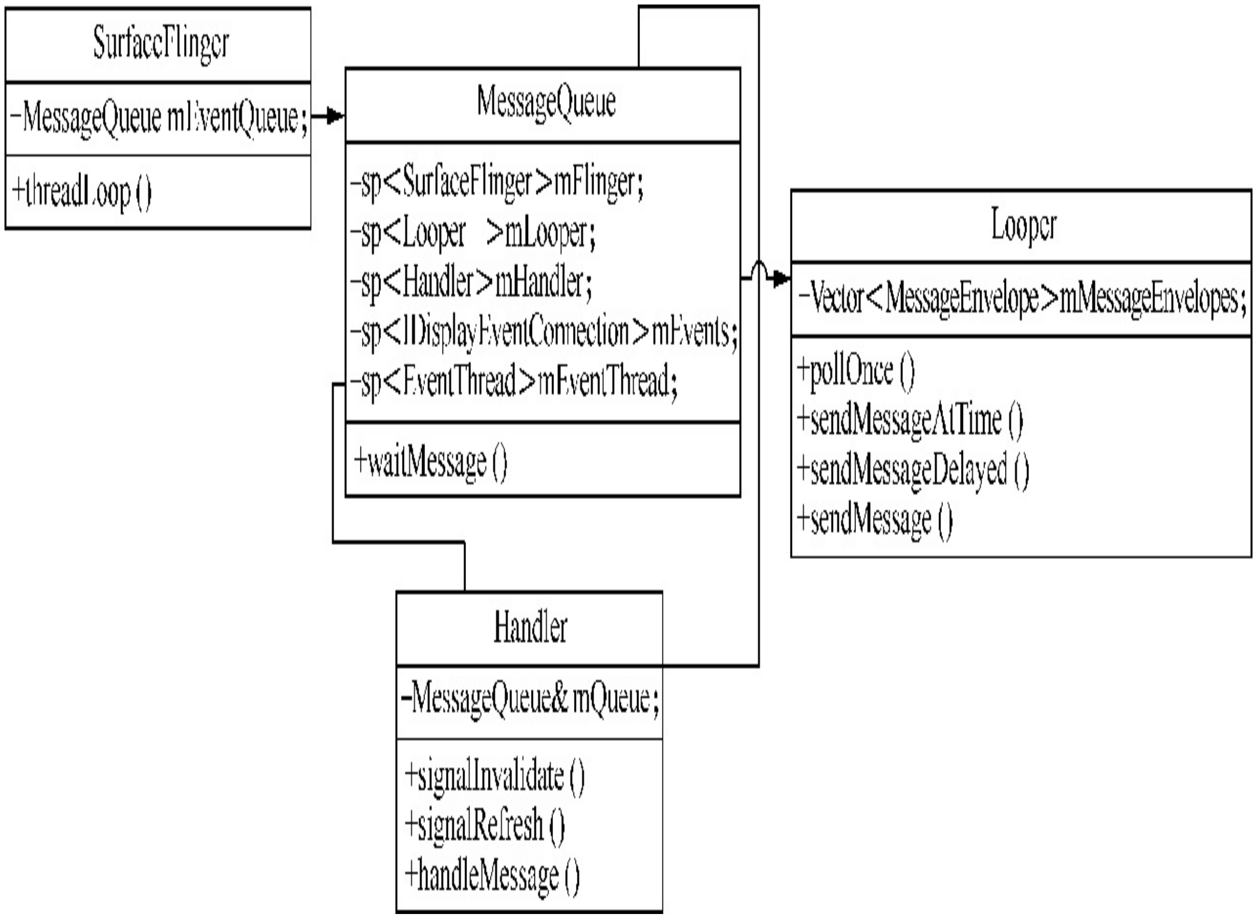

▲图9-29　SurfaceFlinger中的消息循环机制

实际上SurfaceFlinger中的MessageQueue类不应该叫这个名字，因为会和我们传统的消息队列发生混淆和歧义。变量mEventQueue是消息循环处理机制的管理者，其下包含了一个Looper和一个Handler。Looper采用的仍然是/frameworks/native/libs/utils/Looper.cpp中的实现，Surface Flinger没有重新定义这个类。Looper中的mMessageEnvelope才是真正存储消息的地方。

太“绕”了，再好的设计也应该考虑可读性。

这样就构建了一个完整的循环消息处理框架，SurfaceFlinger就是基于这个框架来完成各个应用程序的显示请求的。大家可能会有疑问，mHandler是由MessageQueue在init()中直接通过new Handler()生成的，这样如何能处理特定的SurfaceFlinger消息请求呢？个人感觉有这个困惑也是由于Handler类取名不当引起的。实际上此Handler并非我们经常看到的那个Handler，而是MessageQueue中自定义的一个事件处理

器，即它是专门为SurfaceFlinger设计的：

```
/*frameworks/native/services/surfaceflinger/MessageQueue.cpp*/
void MessageQueue::Handler::handleMessage(const Message& message)
    switch (message.what) {
      case INVALIDATE:
           android_atomic_and(~eventMaskInvalidate, &mEventMask),
           mQueue.mFlinger->onMessageReceived(message.what);
           break;
      case REFRESH:
           android_atomic_and(~eventMaskRefresh, &mEventMask);
           mQueue.mFlinger->onMessageReceived(message.what);
           break;
      case TRANSACTION:
           android_atomic_and(~eventMaskTransaction, &mEventMask
           mQueue.mFlinger->onMessageReceived(message.what);
           break;
    }
}
```

如上述代码段所示，当mHandler收到INVALIDATE，REFRESH及TRANSACTION的请求时，将进一步回调SurfaceFlinger中的onMessageReceived。等于绕了一个大圈，又回到SurfaceFlinger中了。

到目前为止，我们还是没看到SurfaceFlinger是如何通知SystemServer线程解除等待的。这个工作是在下面的函数中完成的：

```
status_t SurfaceFlinger::readyToRun()
{…
    mReadyToRunBarrier.open();//好了，现在可以解禁线程A了
}
```

函数readyToRun是在一个线程进入run循环前被调用的，它为SurfaceFlinger的正常工作提供了各种必要的基础。我们在后续小节还会看到其中的更多内容，这里暂时只分析与消息处理有关的部分。前面所说的mReadyToRunBarrier果然在这里又被调用了，open()用来告诉所有正在等待的线程可以继续执行下一步操作了。Barrier类的内部实际上也是使用了Condition::broadcast()，Condition::wait()等常规互斥方法，只是加了一层封装而已。对同步与互斥这些常用接口方法还不熟悉的读者，建议回头复习下本书的进程章节。

9.6.3 接口的服务端——Client

SurfaceFlinger运行于SystemServer这一系统进程中，需要显示UI界面的应用程序则通过Binder服务与它进行跨进程通信。在后续音频系统的学习中，我们会发现每一个AudioTrack在AudioFlinger中都可以找到一个对应的Track实现，如图9-30所示。这种设计方式同样适用于显示系统，即任何有UI界面的程序都在SurfaceFlinger中有相对应的Client实例。

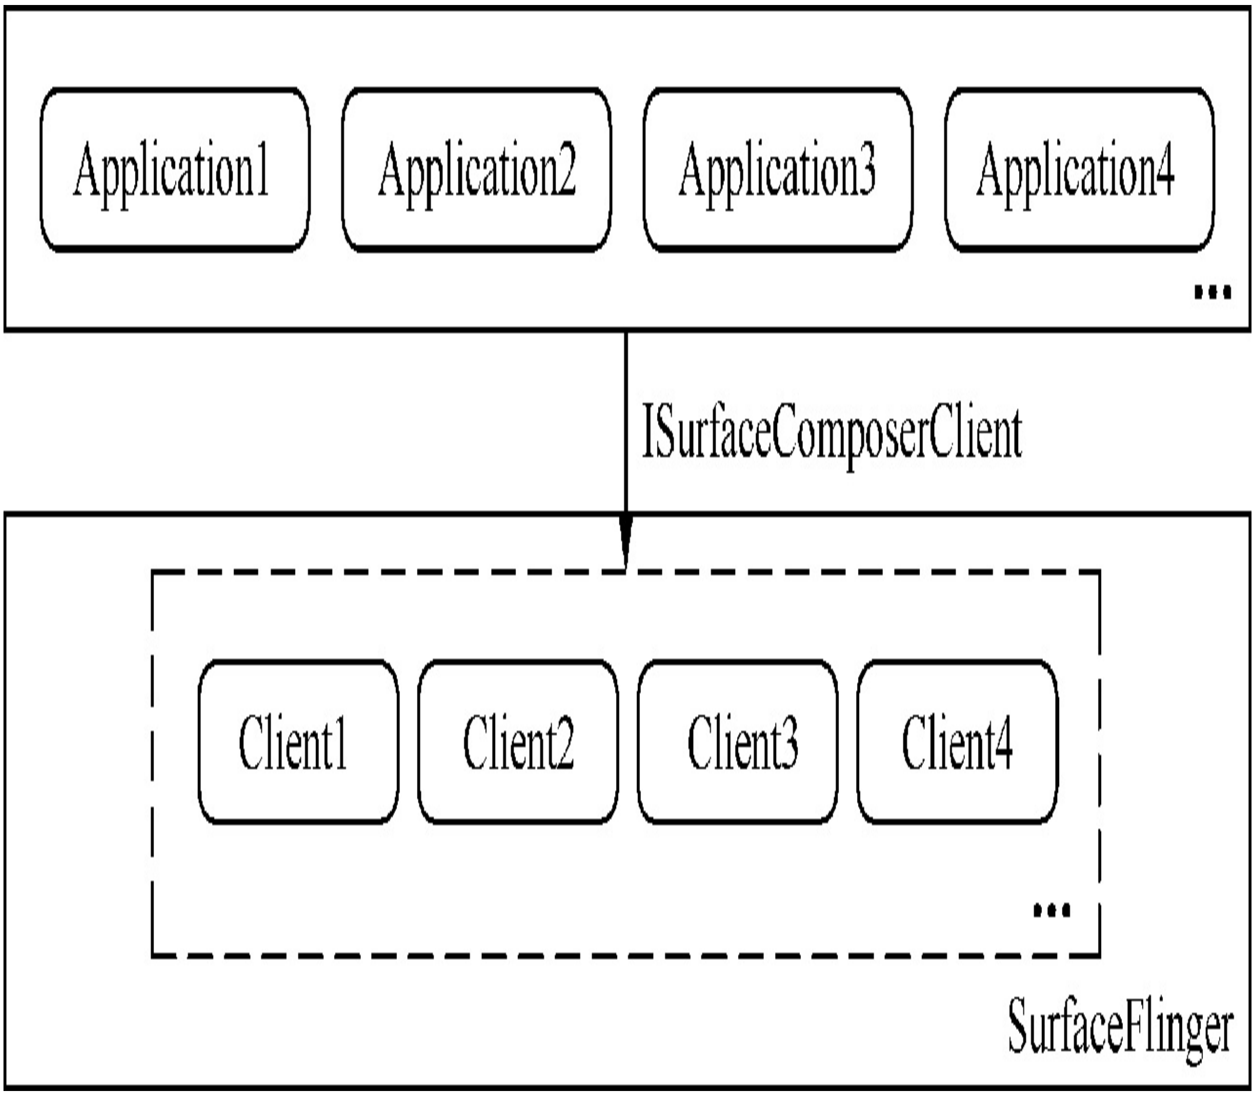

▲图9-30　每个应用程序在SurfaceFlinger中都有Client对象为其提供服务

Client这个类名并没有完全表达出它的真正含义，因为在Android系统的很多其他地方都可以找到同名的类。应用程序与Client间的

Binder接口是ISurfaceComposerClient，所以作为接口的服务端实现，Client继承自BnSurfaceComposerClient：

```
/*frameworks/native/include/gui/ISurfaceComposerClient.h*/
class ISurfaceComposerClient : public IInterface
{   …
virtual status_t createSurface(const String8& name, uint32_t w, u
                       uint32_t flags, sp<IBinder>* handle, sp<IG
                       gbp) = 0;
    virtual status_t destroySurface(const sp<IBinder>& handle) =
};
```

上述接口方法中最重要的两个是createSurface()和destroySurface()，分别用于向SurfaceFlinger申请和销毁一个Surface（早期版本的系统中createSurface返回的是一个叫作ISurface的Binder接口，目前已经不复存在。但createSurface这个函数名称还没有变。我们可以认为Surface在服务器端对应的是Layer）。

值得一提的是，SurfaceFlinger的客户端程序拥有的Surface数量很可能不止一个。通常情况下，同一个Activity中的UI布局共用系统分配的Surface进行绘图，但像SurfaceView这种UI组件却是特例——它独占一个Surface进行绘制。换句话说，如果我们制作一个带SurfaceView的视频播放器，其所在的应用程序最终就会有不止一个的Surface存在。这样的设计是必需的，因为播放视频对刷新频率要求很高，采用单独的Surface既可以保证视频的流畅度，同时也可以让用户的交互动作（比如触摸事件）得到及时的响应。

Client的继承关系如图9-31所示。

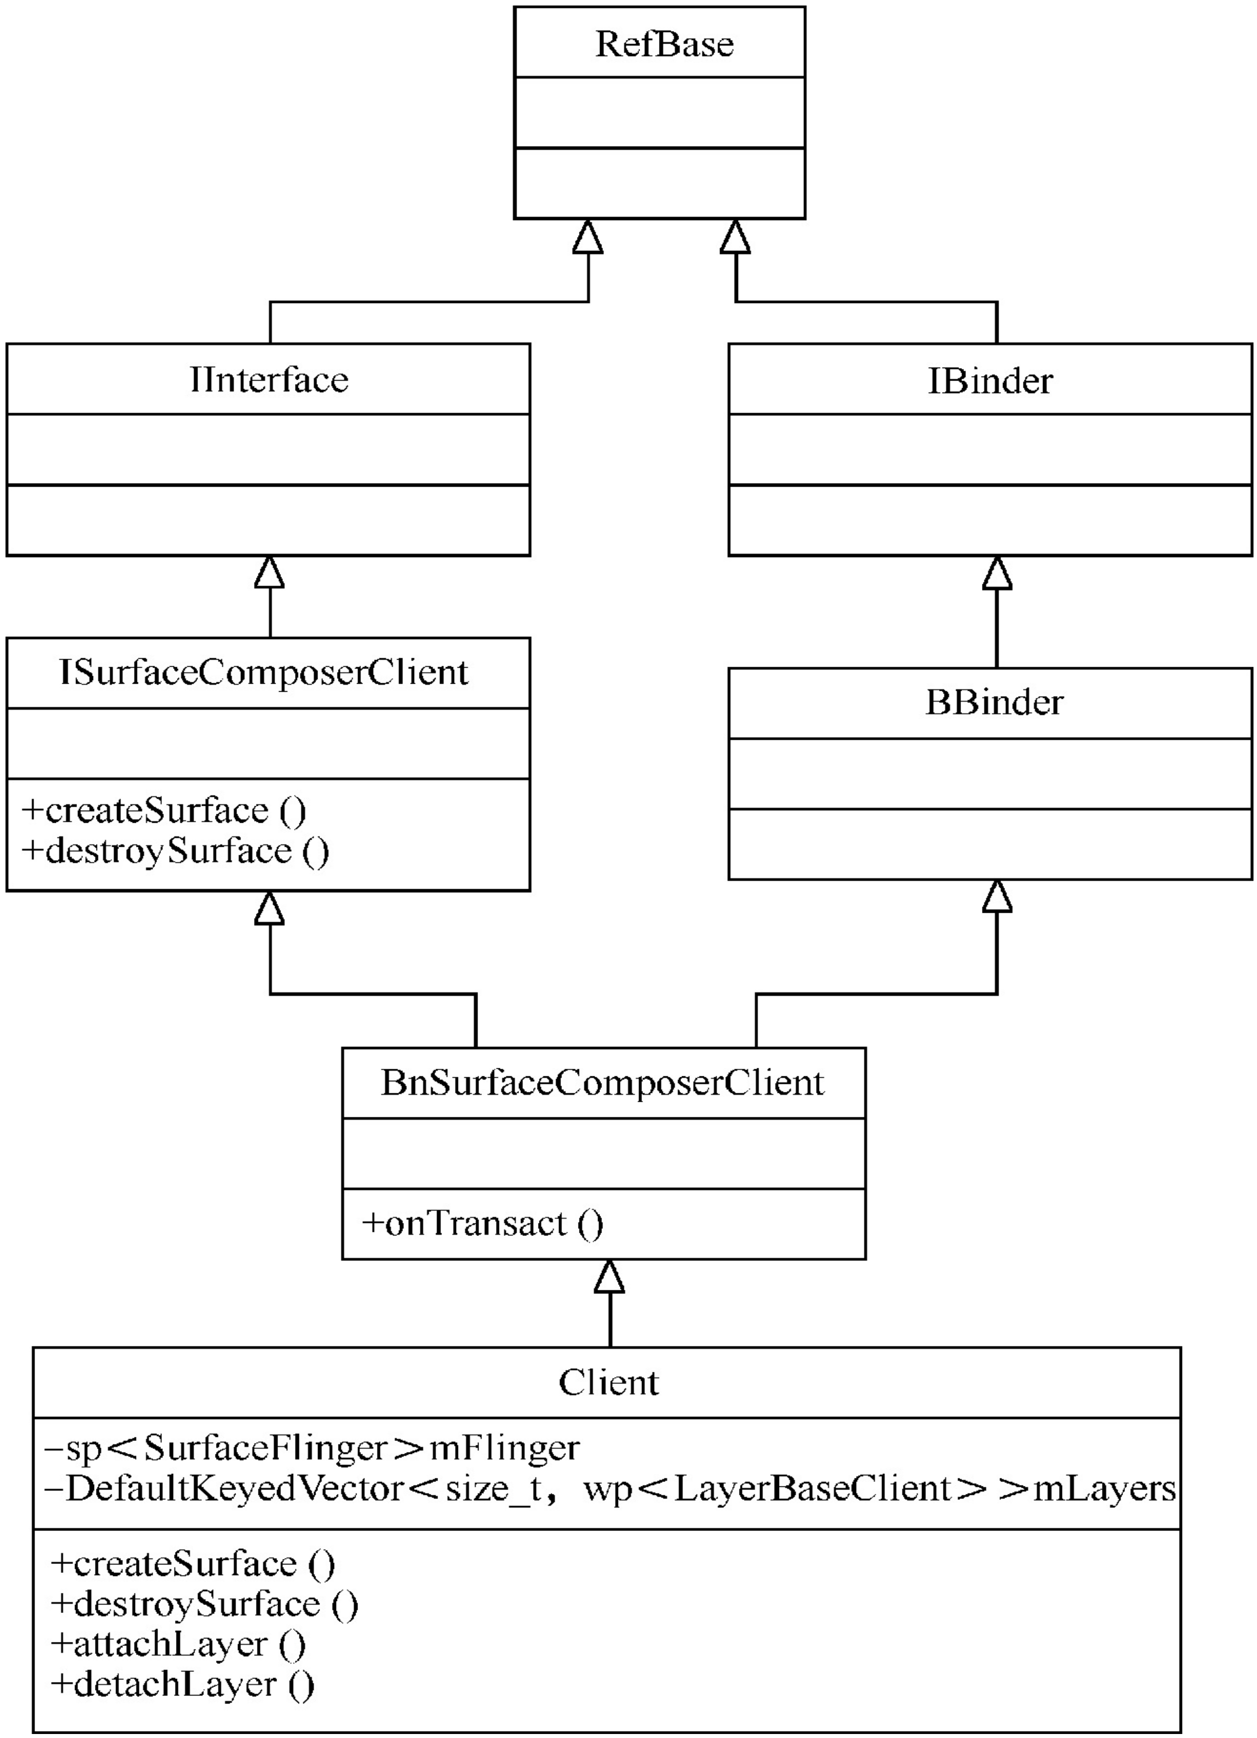
RefBase
IInterface
IBinder
ISurfaceComposerClient
+createSurface ()
+destroySurface ()
BBinder
BnSurfaceComposerClient
+onTransact ()
Client
-sp<SurfaceFlinger>mFlinger
-DefaultKeyedVector<size_t, wp<LayerBaseClient> >mLayers
+createSurface ()
+destroySurface ()
+attachLayer ()
+detachLayer ()

▲图9-31 ISurfaceComposerClient的服务端实现

下面我们从源码角度来分析客户端与SurfaceFlinger连接并创建Layer的两个重要接口。

1．SurfaceFlinger::createConnection

Client属于匿名Binder服务，外界的进程不可能直接获取到，因而它首先需要借助于SurfaceFlinger这一实名Binder Server。源码实现如下：

```
sp<ISurfaceComposerClient> SurfaceFlinger::createConnection()
{
    sp<ISurfaceComposerClient> bclient;
    sp<Client> client(new Client(this));
    status_t err = client->initCheck();
    if (err == NO_ERROR) {
        bclient = client;
    }
    return bclient;
}
```

首先生成一个Client本地对象，然后调用initCheck进行必要的有效性检查（当前实现中直接返回NO_ERROR）。如果initCheck没有错误，程序就会把新生成的Client对象以IsurfaceComposer Client强指针的形式返回。

这样应用程序内部就拥有一个Client服务了。

2．Client::createSurface

Client只是SurfaceFlinger分派给应用程序的一个“代表”，真正的图形层（Layer）创建需要另外申请，即调用Client提供的createSurface接口。这个接口的实现在前几个小节已经有过粗略的分析，下面再从SurfaceFlinger的角度来审视下：

```
/*frameworks/native/services/surfaceflinger/Client.cpp*/
status_t Client::createSurface(const String8& name, uint32_t w, u
{
    class MessageCreateLayer : public MessageBase {
```

```
        SurfaceFlinger* flinger;//SurfaceFlinger服务
        Client* client;//表明此消息来源于哪个Client
        sp<IBinder>* handle;//与Layer相对应的Handle
        sp<IGraphicBufferProducer>* gbp;//与Layer相对应的gbp
        status_t result;
        const String8& name;
        uint32_t w, h;
        PixelFormat format;
        uint32_t flags;
    public:
        MessageCreateLayer(SurfaceFlinger* flinger, const String8
                           uint32_t h, PixelFormat format, uint32
                           sp<IBinder>* handle, sp<IGraphicBuffer
            : flinger(flinger), client(client), handle(handle), g
              name(name), w(w), h(h), format(format), flags(flags
        }
        status_t getResult() const { return result; }
        virtual bool handler() {//SurfaceFlinger将回调这个handler来
            result = flinger->createLayer(name, client, w, h, for
            return true;
        }
    };

    sp<MessageBase> msg = new MessageCreateLayer(mFlinger.get(),
            name, this, w, h, format, flags, handle, gbp);//生成一
    mFlinger->postMessageSync(msg);//将这一Message推送到SurfaceFlin
    return static_cast<MessageCreateLayer*>( msg.get() )->getResu
}
```

值得注意的是，createSurface这个函数需要从OpenGL ES的环境线程中被调用，这样它才能访问到后者提供的服务。

这个函数比较特别的地方，是它先在内部创建了一个MessageCreateLayer类，剩余部分代码就是围绕这个类来展开的。那么，MessageCreateLayer有什么作用呢？从名称上看，它应该和Message有关——其父类是MessageBase，定义在MessageQueue.h中，如图9-32所示。

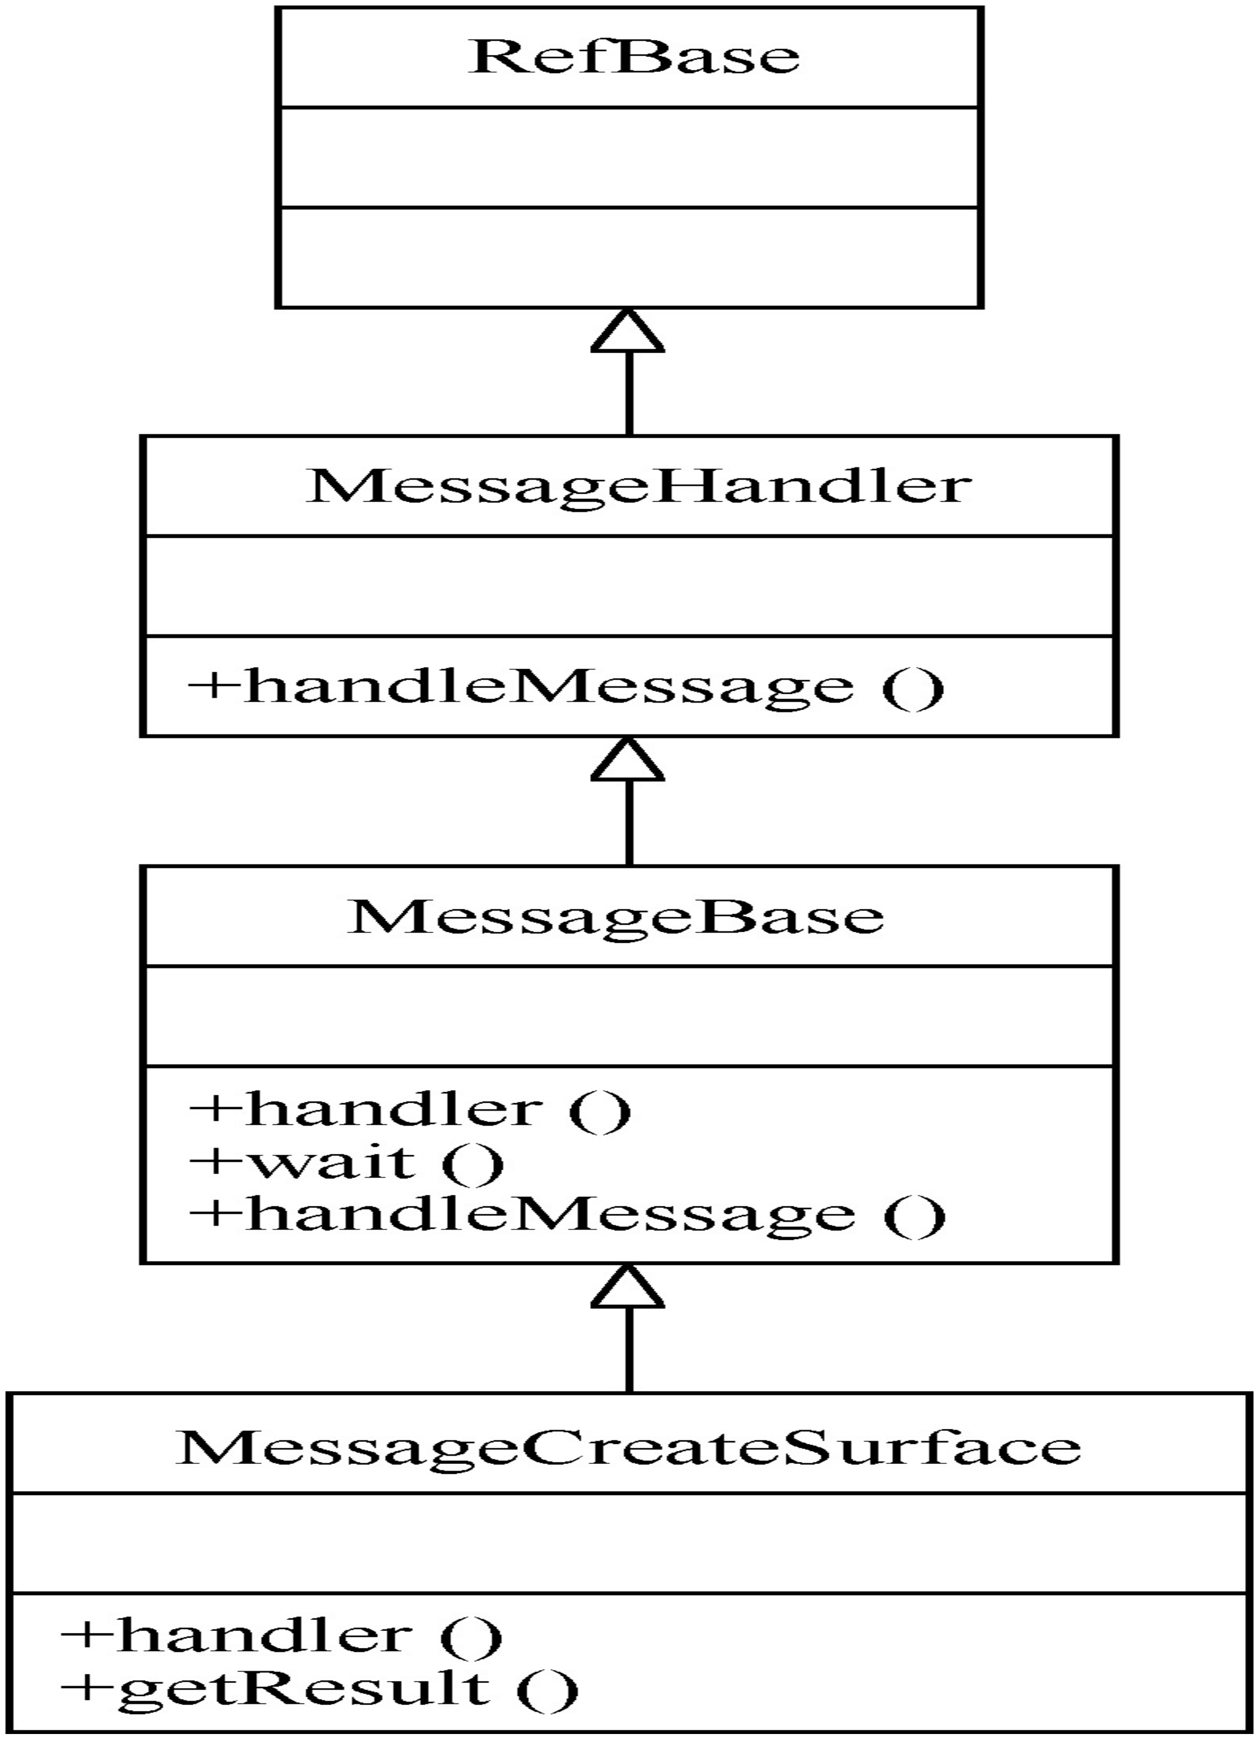
RefBase
MessageHandler
+handleMessage ()
MessageBase
+handler ()
+wait ()
+handleMessage ()
MessageCreateSurface
+handler ()
+getResult ()

▲图9-32 MessageCreateLayer

从继承图中可以大概看出一点端倪，即MessageCreateLayer是一个Message的承载体，并且内部提供了处理这条Message的handler()函数。这是不是和Java层的Handler很像？可能也是这个原因，所以其“祖谱”中有一个类取名为MessageHandler。回过头来看createSurface中的最后几行，程序将一个MessageCreateLayer对象msg发送到了SurfaceFlinger中：

```
mFlinger->postMessageSync(msg);
```

为什么要这么做呢？

大家还记不记得在进程章节讲述Message，Looper，Handler的关系时曾经打过一个比方，为了方便阅读我们再把它列出来：

“……

打个比方，某天你和朋友去健身房运动，正当你在跑步机上气喘吁吁时，旁边有个朋友跟你说：“哥们儿，最近手头紧，借点钱花花。”这时候你就有两个选择。

- 立即执行

这就意味着你要从跑步机上下来，问清借多少钱，然后马上打开电脑进行转账。

- 稍后执行

上面的方法在某些场合下是有用的，不过大部分情况下“借钱”这种事并不是刻不容缓的，因而你可以跟朋友说：“借钱没问题，你先和我秘书约时间，改天我们具体谈细节。”那么在这种情况下，这个“借钱事件”就通过秘书这个MessageQueue进入了排队，所以你并不需要从跑步机上下来，中断健身运动。后期秘书会一件件通知你MessageQueue上的待办事宜（当然你也可以主动问秘书），直到“借钱事件”时你才需要和这位朋友进一步商谈。在一些场合下这样的处理方式是合情合理的。比如健身房一小时花费是10万元，而朋友只借100元，那么即刻处

理这一事件就不合理了。

这个“借钱”的例子在createSurface()这个场景中也是同样适用的，如图9-33所示。

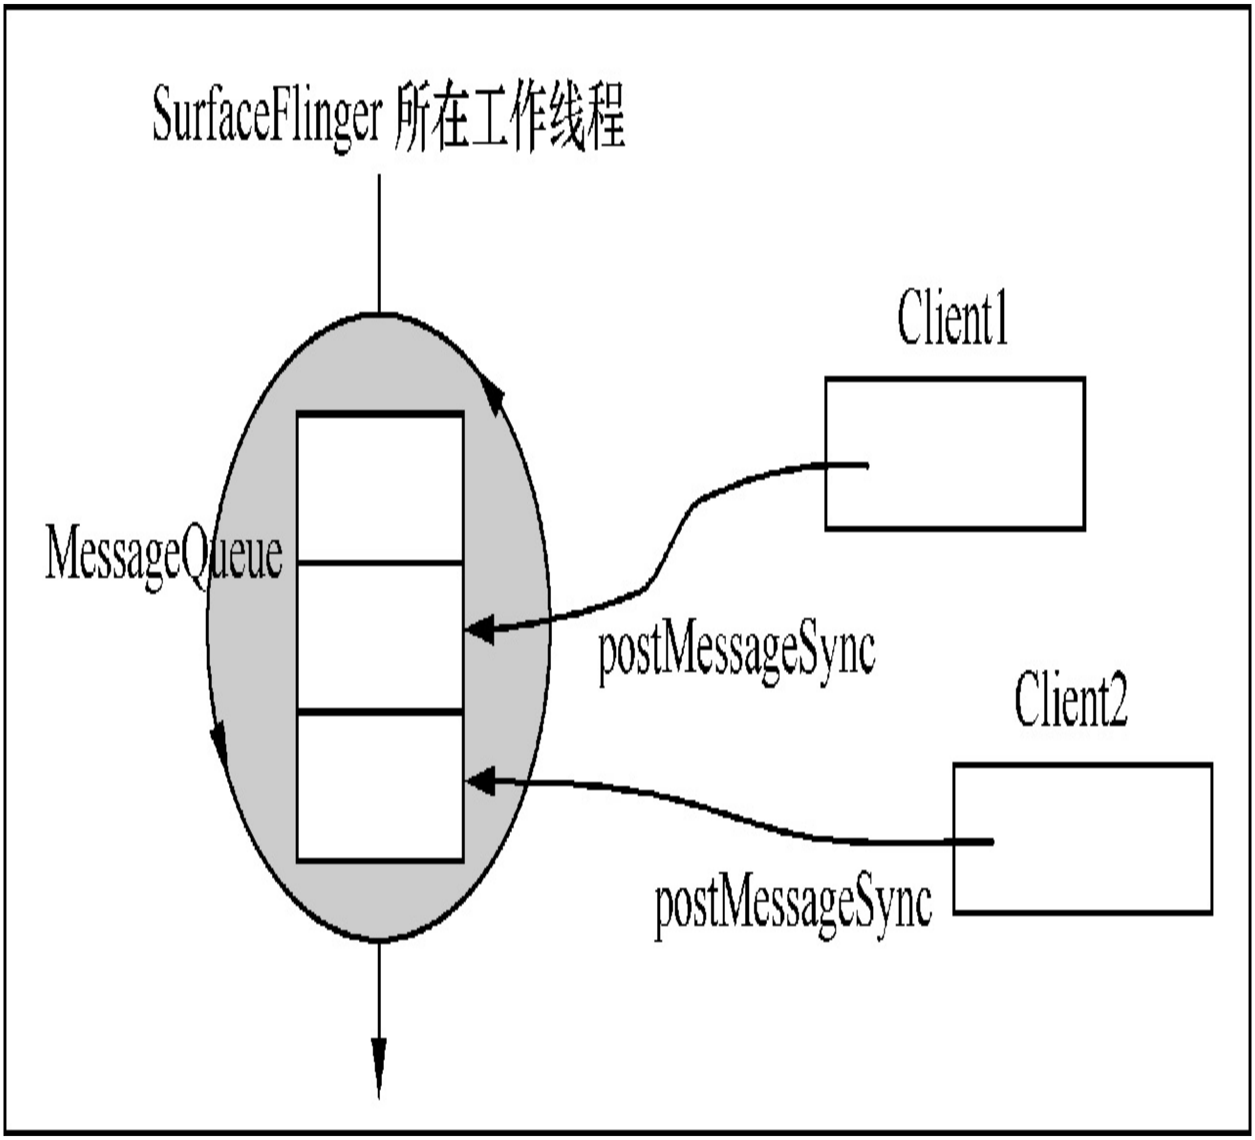

▲图9-33　createSurface中的消息投递与执行

函数postMessageSync是SurfaceFlinger提供的一个接口，它通过mEventQueue将Msg压入其消息队列中，并且会进入等待状态。如下：

```
status_t SurfaceFlinger::postMessageSync(const sp<MessageBase>& m
    status_t res = mEventQueue.postMessage(msg, reltime);
    if (res == NO_ERROR) {
```

```
        msg->wait();
    }
    return res;
}
```

MessageBase::wait()调用内部的Barrier::wait来实现等待，这意味着发送消息的线程将暂时停止执行，那么什么时候才能继续呢？显然得有人唤醒它才行。这个唤醒的地方隐藏在MessageBase::handleMessage()中。即：

```
/*frameworks/native/services/surfaceflinger/MessageQueue.cpp*/
void MessageBase::handleMessage(const Message&) {
    this->handler();
    barrier.open();
};
```

简单来讲，就是Client一旦收到来自客户端的请求，并不会马上让SurfaceFlinger执行，而是间接地把请求先投递到后者的消息队列中——这样一方面保证这个请求不会丢失，另一方面也使SurfaceFlinger不至于中断当前的操作。

在createSurface的执行过程中，显然Client所在线程（即Binder线程）将进入wait状态，直到SurfaceFlinger成功完成业务后，它才被唤醒，然后返回最终结果给客户端——这一工作方式和postMessageSync所要实现的“同步”是一致的。

这其中的流程有点乱，我们以图9-34来做下整理。

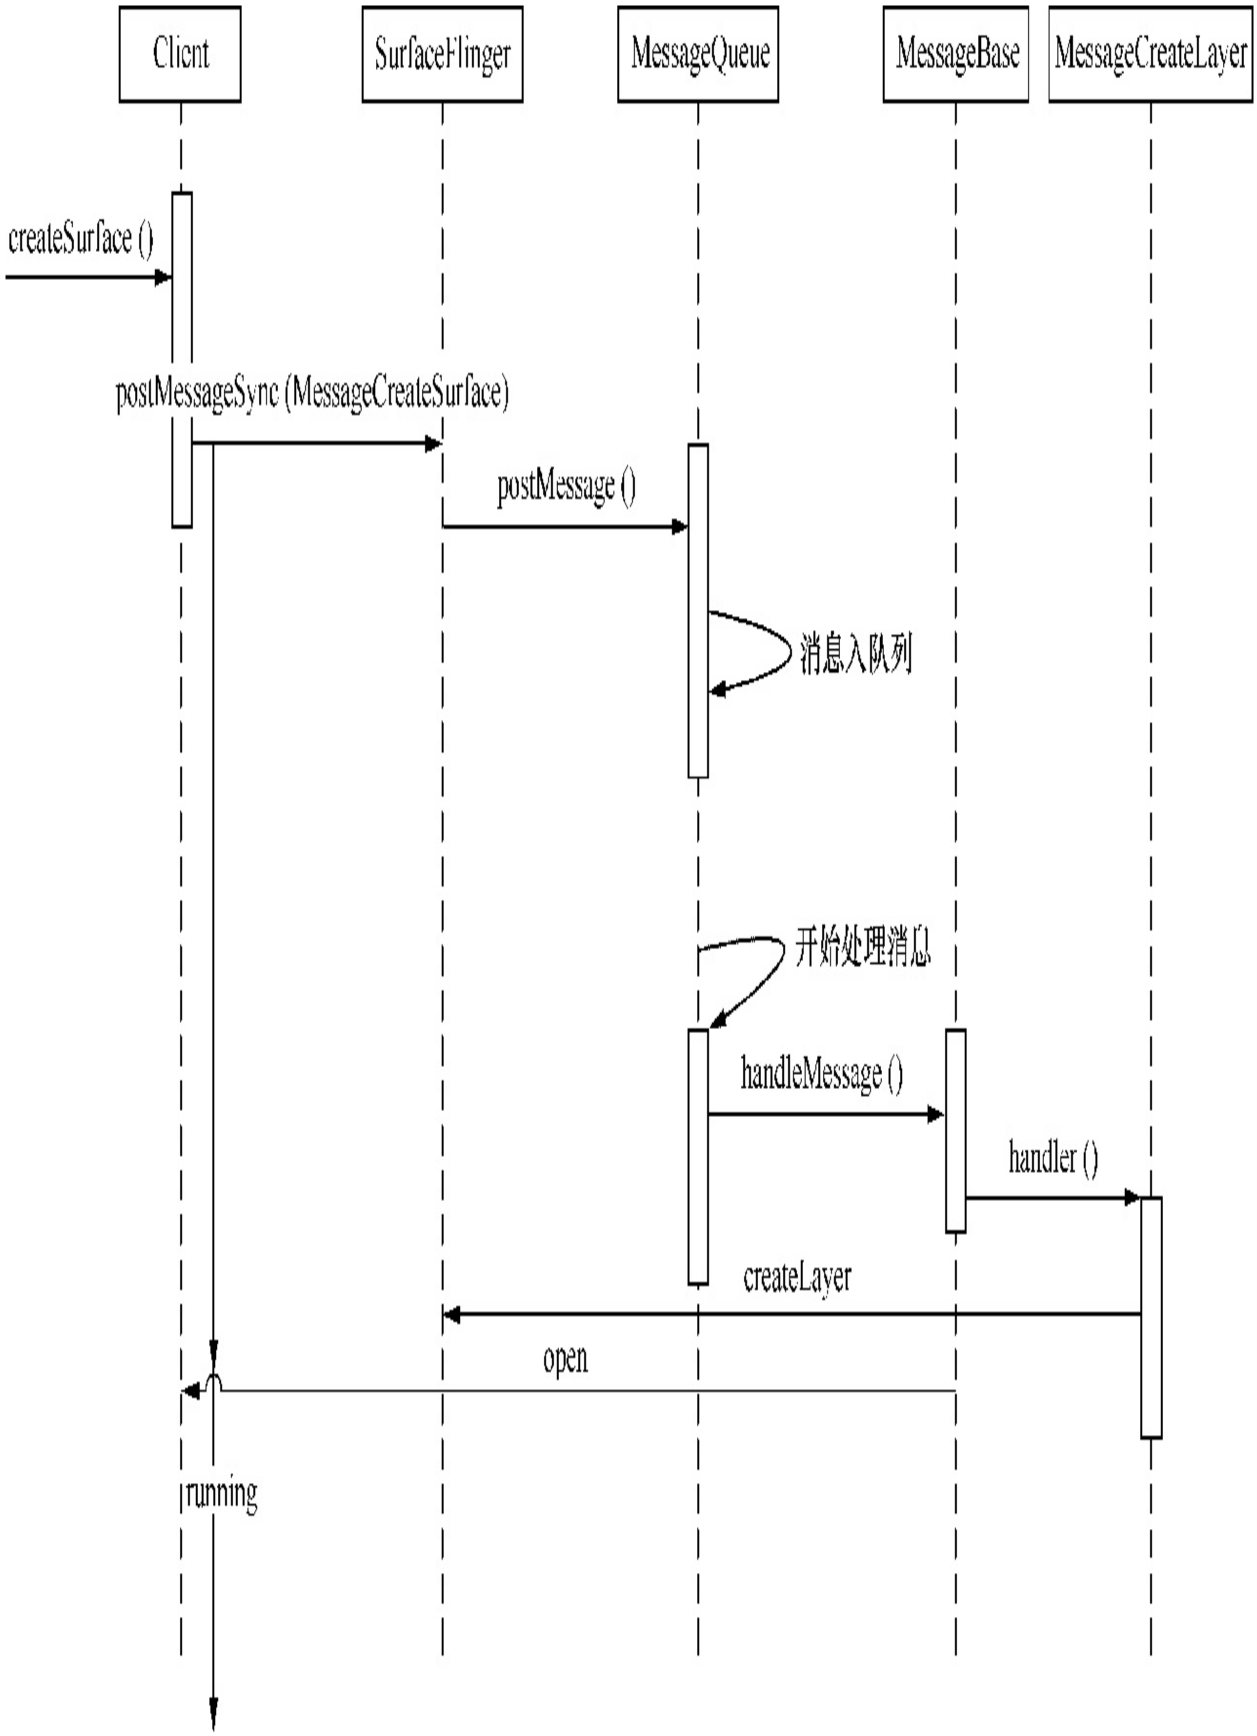

Client
SurfaceFlinger
MessageQueue
MessageBase
MessageCreateLayer
createSurface ()
postMessageSync (MessageCreateSurface)
postMessage ()
消息入队列
开始处理消息
handleMessage ()
handler ()
createLayer
open
running

▲图9-34 Client::createSurface流程图

另外，SurfaceFlinger中还有一个类似的消息推送函数postMessageAsync，从名称上就可以看出它是用来异步执行业务的。通俗地讲就是推送消息过后函数就直接返回了，而无须等待执行结果。读者可以自行分析下这个函数的源码。

绕了一圈，终于轮到SurfaceFlinger工作线程来处理createSurface()了。这个函数我们在前面讲解“应用程序与BufferQueue的关系”时已经详细分析过，这里不再赘述。

9.7 VSync的产生和处理

大家在Project Butter小节中学习了从Android 4.1开始引入的显示系统新特性——这个工程的一个重要核心就是加入了VSync同步。我们从理论的角度分析了采用这一机制的必要性和运作机理，那么SurfaceFlinger具体是如何实施的呢？

先来思考一下SurfaceFlinger实现VSync同步有哪些要点。

- VSync信号的产生和分发

如果有硬件主动发出这一信号，那是最好的；否则就得通过软件模拟产生。

- VSync信号的处理

当信号产生后，SurfaceFlinger如何在最短的时间内做出响应。另外，具体的处理流程是怎样的。

9.7.1 VSync信号的产生和分发

Android源码工程的surfaceflinger目录下有一个displayhardware文件夹，其中HWComposer的主要职责之一，就是用于产生VSync信号：

```
/*frameworks/native/services/surfaceflinger/displayhardware/HWCom
HWComposer::HWComposer(const sp<SurfaceFlinger>& flinger, EventHa
      : mFlinger(flinger), mFbDev(0), mHwc(0), mNumDisplays(1), m
      mEventHandler(handler), mVSyncCount(0), mDebugForceFakeVSyn
{…
    char value[PROPERTY_VALUE_MAX];
    property_get("debug.sf.no_hw_vsync", value, "0");//获取系统属性
    mDebugForceFakeVSync = atoi(value);
    bool needVSyncThread = true;//是否需要软件模拟产生VSync信号，默认是
    …
    loadHwcModule();//打开HWC的HAL模块
    …
    if (mHwc) {…
        if (mHwc->registerProcs) {//注册硬件回调事件
            mCBContext->hwc = this;
            mCBContext->procs.invalidate = &hook_invalidate;
```

```
            mCBContext->procs.vsync = &hook_vsync;
            if (hwcHasApiVersion(mHwc, HWC_DEVICE_API_VERSION_1_1
                mCBContext->procs.hotplug = &hook_hotplug;
            else
                mCBContext->procs.hotplug = NULL;
            memset(mCBContext->procs.zero, 0, sizeof(mCBContext->
            mHwc->registerProcs(mHwc, &mCBContext->procs);
        }

        // don't need a vsync thread if we have a hardware compos
        needVSyncThread = false;//不需要软件模拟
        …
    }
    …
    if (needVSyncThread) {///如果需要软件模拟VSync信号的话，启动一个VSy
        // we don't have VSYNC support, we need to fake it
        mVSyncThread = new VSyncThread(*this);
    }
}
```

这个函数的核心就是决定VSync的“信号发生源”——硬件实现或者软件模拟。

假如当前系统可以成功地加载名称为HWC_HARDWARE_MODULE_ID=“hwcomposer”的HAL模块，并且通过这个库模块能顺利打开设备（hwc_composer_device_t），其版本号又大于HWC_DEVICE_API_VERSION_1_1，我们就采用“硬件源”（此时needVSyncThread为false）；否则需要创建一个新的VSync线程来模拟产生信号。

1．硬件源

如果mHwc->registerProcs不为空，我们注册硬件回调mCBContext.procs。定义如下：

```
struct HWComposer::cb_context {
    struct callbacks : public hwc_procs_t {
        void (*zero[4])(void);
    };
    callbacks procs;
    HWComposer* hwc;
};
```

调用registerProcs()时，传入的参数是&mCBContext.procs。后期当有事件产生时，如vsync或者invalidate，硬件模块将分别通过procs.vsync和procs.invalidate来通知HWComposer：

```
void HWComposer::hook_vsync(struct hwc_procs* procs, int dpy, int
    reinterpret_cast<cb_context *>(procs)->hwc->vsync(dpy, timest
}
```

上面这个函数中procs即前面的&mCBContext.procs，从指针地址的角度看它和&mCBContext是一致的（procs是cb_context的第一个元素），因而我们可以把它的强制类型转换为cb_context来操作，并由此访问到hwc中的vsync实现：

```
void HWComposer::vsync(int dpy, int64_t timestamp) {
    mEventHandler.onVSyncReceived(dpy, timestamp);
    …
}
```

HWComposer将VSync信号直接传递给mEventHandler，这个Handler是由HWComposer在构造时传入的。换句话说，我们需要看看是谁创建了HWComposer：

```
/*frameworks/native/services/surfaceflinger/SurfaceFlinger.cpp*/
status_t SurfaceFlinger::readyToRun()
{…
    mHwc = new HWComposer(this,*static_cast<HWComposer::EventHand
```

从中可以看出，HWComposer中的mEventHandler就是SurfaceFlinger对象，所以后者必须要继承自HWComposer::EventHandler，这样才能处理callback函数onVSyncReceived：

```
class SurfaceFlinger : public BinderService<SurfaceFlinger>,…
                       private HWComposer::EventHandler
```

早期版本的实现中，还有另外一个类DisplayHardware来间接处理EventHandler，再通过一系列的传递才能到达SurfaceFlinger本身的处理。可以说Android 4.3中对这些中间冗余过程进行了精简，很值得称道。

2. 软件源

软件源和硬件源相比最大区别是它需要启动一个新线程VSyncThread，其运行优先级与SurfaceFlinger的工作线程是一样的，都是-q。从理论的角度来讲，任何通过软件定时来实现的机制都不可能是100%可靠的，即使优先级再高也可能出现延迟和意外。不过如果“不可靠”的概率很小，而且就算出现意外时也不至于是致命错误，那么还是可以接受的。所以说VSyncThread从实践的角度来讲，的确起到了很好的作用。

来看看VSyncThread都做了些什么工作：

```
bool HWComposer::VSyncThread::threadLoop() {
   /*Step1. 判断系统是否使能了VSync信号发生机制*/
    { // 自动锁控制范围
        Mutex::Autolock _l(mLock);
        while (!mEnabled) {//VSync信号开关
            mCondition.wait(mLock);
        }
    }
    /*Step2. 计算需要产生VSync信号的时间点*/
    const nsecs_t period = mRefreshPeriod;//信号的产生间隔
    const nsecs_t now = systemTime(CLOCK_MONOTONIC);
    nsecs_t next_vsync = mNextFakeVSync;//产生信号的时间
    nsecs_t sleep = next_vsync - now; //需要休眠的时长
    if (sleep < 0) {//已经过了时间点
        sleep = (period - ((now - next_vsync) % period));
        next_vsync = now + sleep;
    }
    mNextFakeVSync = next_vsync + period; //下一次的VSync时间
    struct timespec spec;
    spec.tv_sec  = next_vsync / 1000000000;
    spec.tv_nsec = next_vsync % 1000000000;

    int err;
    do {
        err = clock_nanosleep(CLOCK_MONOTONIC, TIMER_ABSTIME, &sp
    } while (err<0 && errno == EINTR);

    if (err == 0) {
        mHwc.mEventHandler.onVSyncReceived(0, next_vsync);//和硬件
    }
    return true;
}
```

Step1@VSyncThread::threadLoop。关于自动锁的使用我们已经分

析过很多次，此处不再赘述。这里要注意的是mEnabled这个变量，它是用于控制是否产生VSync信号的一个使能变量。当系统希望关闭VSync信号发生源时，可以调用VSyncThread::setEnabled(false)；否则调用setEnabled（true）。假如mEnabled为false，VSyncThread就处于等待状态，直到有人再次使能这个线程。

Step2@VSyncThread::threadLoop。接下来的代码用于真正产生一个VSync信号。可以思考一下，无非就是以下步骤：

- 计算下一次产生VSync信号的时间；
- 进入休眠；
- 休眠时间到了后，发出VSync信号，通知感兴趣的人；
- 循环往复。

变量mRefreshPeriod指定了产生VSync信号的间隔。它的计算过程分为几种情况：首选是从硬件设备获得真实的值；否则就采用如下办法：

```
        if (disp.refresh == 0) {
            disp.refresh = nsecs_t(1e9 / mFbDev->fps);
        }
        if (disp.refresh == 0) {
            disp.refresh = nsecs_t(1e9 / 60.0);
        }
```

也就是说第二优先级的取值是由nsecs_t(1e9 / mFbDev->fps)计算得到的——如果还不行，那就只能采用默认值了。即：

```
nsecs_t(1e9 / mRefreshRate);
```

在这种情况下，mRefreshPeriod差不多是16ms。

因为mNextFakeVSync代表的是“下一次”产生信号的时间点，所以首先通过next_vsync= mNextFakeVSync来确定next_vsync的值。接着计算sleep，也就是距离产生信号的时间点还有多长（同时也是需要休眠的时间）。那么，如果sleep的结果小于0呢？代表我们已经错过了这一次产生信号的最佳时间点（这是有可能发生的）。在这种情况下，就只能计算下一个最近的VSync离现在还剩多少时间。公式如下：

```
sleep = (period - ((now - next_vsync) % period));
```

我们以图9-35来表述以下采用这个公式的依据。

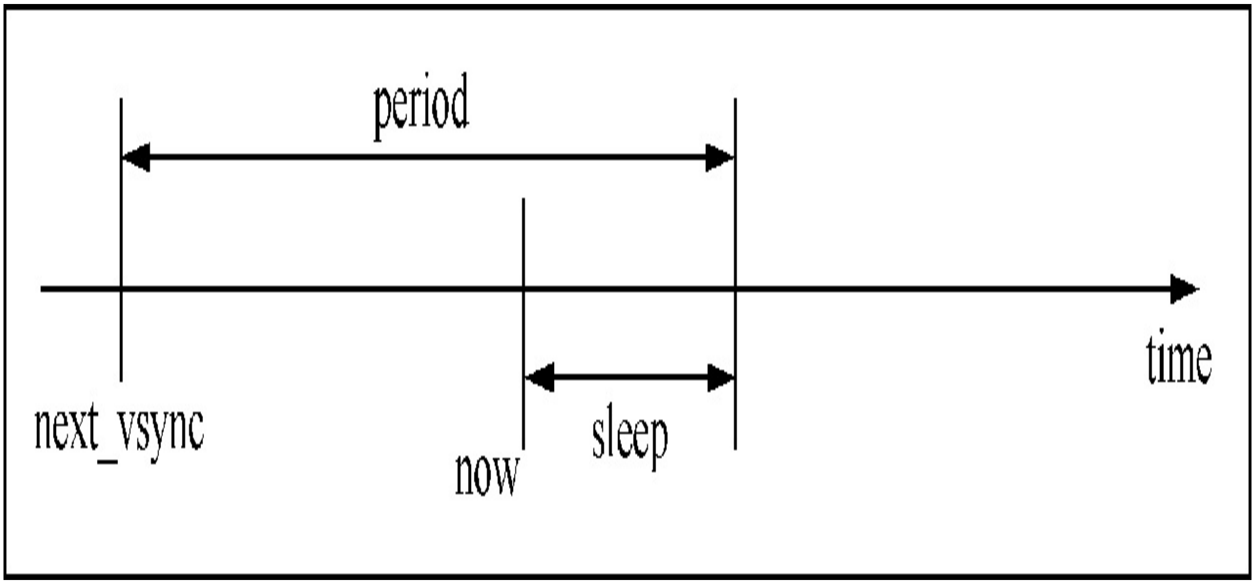

▲图9-35　休眠时间推算简图

图9-35的前提是now超时时间不能超过一个period——因而sleep公式中还要加上%period。

计算完成sleep后，mNextFakeVSync=next_vsync + period。这是因为mNextFakeVSync代表的是下一次threadLoop需要用到的时间点，而next_vsync是指下一次（最近一次）产生VSync的时间点。

这样我们就计算出来下一次产生信号的时间点了，那么如何在指定的时间点产生信号呢？有两种方法：其一是采用定时器回调；其二就是采用休眠的形式主动等待——HWComposer使用的是后者。

可想而知这里对时间精度的要求比较高，所以采用的单位是nanosecond，即纳秒级。函数clock_nanosleep的第一个入参是CLOCK_MONOTONIC，这种类型的时钟更加稳定，且不受系统时间的影响。

休眠时间一到，表示产生信号的时刻到了。根据前面的分析，就是通过mEventHandler. onVSyncReceived()回调来通知对消息感兴趣的人——无论软件还是硬件发生源，其回调方式都是一样的。

当产生完一次信号后，VSyncThread::threadLoop这个函数就直接返回true了。有些读者可能会觉得奇怪，怎么没有看到循环的地方？这是因为当threadLoop返回值为“真”时，它将被系统再一次调用，如此循环往复。不清楚的读者可以参阅一下Thread类的实现。

接下来我们分析下SurfaceFlinger是如何处理这个VSync信号的。

中间过程很简单，就不一一解释了。在SurfaceFlinger::onVSyncReceived中：

```
void SurfaceFlinger::onVSyncReceived(int type, nsecs_t timestamp)
    …
    if (uint32_t(type) < DisplayDevice::NUM_DISPLAY_TYPES) {
        // we should only receive DisplayDevice::DisplayType from
        mEventThread->onVSyncReceived(type, timestamp);//EventThr
    }
}
```

又出现了一个新类，即EventThread。SurfaceFlinger直接调用了它的onVSyncReceived实现。从名称上可以猜测到，EventThread是SurfaceFiInger中专门用于处理事件的线程。这个线程对象是在SurfaceFlinger::readyToRun生成的：

```
status_t SurfaceFlinger::readyToRun()
{…
    mEventThread = new EventThread(this);
    mEventQueue.setEventThread(mEventThread);
```

注意

EventQueue与EventThread进行了绑定，后续我们还会再分析它们之间的关系。

EventThread的启动并不是由SurfaceFlinger决定的，而是取决于引用它的人——因为EventThread继承自Thread，后者又是RefBase的子类，所以当第一次有人用智能指针引用它时，会自动调用onFirstRef函数，继而把这个线程run起来（线程优先级为PRIORITY_URGENT_DISPLAY + PRIORITY_MORE_FAVORABLE）。

了解了EventThread的启动过程后，再来看看它是如何处理消息的：

```
/*frameworks/native/services/surfaceflinger/EventThread.cpp*/
void EventThread::onVSyncReceived(int type, nsecs_t timestamp) {…
    Mutex::Autolock _l(mLock);
    if (type < HWC_NUM_DISPLAY_TYPES) {//显示类型目前有两种
        mVSyncEvent[type].header.type = DisplayEventReceiver::DIS
        mVSyncEvent[type].header.id = type;
        mVSyncEvent[type].header.timestamp = timestamp;
        mVSyncEvent[type].vsync.count++;
        mCondition.broadcast();//条件满足，唤醒谁？
    }
}
```

Android4.3版本中，HWC_NUM_DISPLAY_TYPES的定义如下：

```
enum {
    HWC_DISPLAY_PRIMARY = 0,
    HWC_DISPLAY_EXTERNAL = 1,    // HDMI, DP, etc.
    HWC_NUM_DISPLAY_TYPES
};
```

可以看到，Android系统除了主显示屏外，还支持HDMI的显示（或者称为外部显示屏）。所以VSync的产生者类型值只会小于HWC_NUM_DISPLAY_TYPES。

确定了Display Type后，函数根据具体的类型来填充mVSyncEvent[type]数组中的DisplayEventReceiver::Event对象，包括Event类型、时间戳、信号计数等。而最重要的是，程序在函数末尾通过mCondition.broadcast()来通知等待Event的人——会是谁呢？

没错，是EventThread所在的线程。可能有人会觉得奇怪，onVSyncReceived不就是属于EventThread吗，怎么还能处于等待中？发出这种疑问可能是被线程的概念“困”住了。由上面的分析可以看出，EventThread::onVSyncReceived其实是由SurfaceFlinger所在线程调用的，所以它的执行也是由SurfaceFlinger所在线程完成的——不过onVSyncReceived并没有对信号做具体的处理。打个比方，SurfaceFlinger线程只是到了EventThread家的厨房（onVSyncReceived）里，然后把“食材”通过DisplayEventReceiver::Event准备好，放在mVSyncEvent中，然后唤醒

正在屋里睡大觉的“EventThread”——嘿，哥们儿，东西都准备好了，开动吧！于是接下来的处理工作就正式移交到EventThread线程了。

这点我们从下面这个代码段中也能得到验证：

```
bool EventThread::threadLoop() {
    DisplayEventReceiver::Event event;
    Vector< sp<EventThread::Connection>> signalConnections;
    signalConnections = waitForEvent(&event);//EventThread就是在这里
    const size_t count = signalConnections.size();
    for (size_t i=0 ; i<count ; i++) {//开始dispatch消息给所有感兴趣的
        const sp<Connection>& conn(signalConnections[i]);
        status_t err = conn->postEvent(event);//通过Connection“通道
        …
    }
    return true;//如我们前面所述，返回true后系统将再次调用threadLoop
}
```

首先还得强调下，当threadLoop返回true时，系统将会再次调用它，从而形成一个循环。在一个单次循环中，它会利用waitForEvent来等待一个事件的发生，如VSync。我们前面所说的EventThread在“睡大觉”，就是由此引起的。而一旦mCondition.broadcast()后，它就会得到唤醒。

接着EventThread会统计所有对Event感兴趣的人，即记录在signalConnections中的元素。然后它通过与这些元素间的纽带（Connection）来一一通知它们有事件发生了。变量signalConnections是在waitForEvent中准备的，根据Event的实际情况从EventThread的全局变量mDisplayEvent Connections中挑选出来的。

换句话说，所有对Event感兴趣的人都需要被记录到mDisplayEventConnections中。具体而言，有两种类型的“忠实听众”。

- SurfaceFlinger

毋庸置疑，SurfaceFlinger一定会收听VSync信号的产生。这一工作由它内部的EventQueue，即“事件队列管家”来完成。当SurfaceFlinger::readyToRun中生成EventThread对象后，会马上调用

MessageQueue::setEventThread来把它设置到内部的mEventThread变量中；同时，MessageQueue还会通过接口EventThread::createEventConnection来创建一个Connection连接。

- 需要刷新UI的各进程

SurfaceFlinger只是负责最后的UI数据合成，而各应用程序才是真正的数据生产者，所以它们也必定是要监听VSync信号的。SurfaceFlinger提供了createDisplayEventConnection接口来满足各应用程序的需求，这个接口同样调用了EventThread::createEventConnection来创建一个Connection连接。

那么，什么情况下这些创建的Connection会添加到EventThread的mDisplayEventConnections中呢？

没错，是当这些Connection被第一次引用的时候，它会自动调用registerDisplayEventConnection来注册到EventThread中。

我们以图9-36来总结本小节的内容。

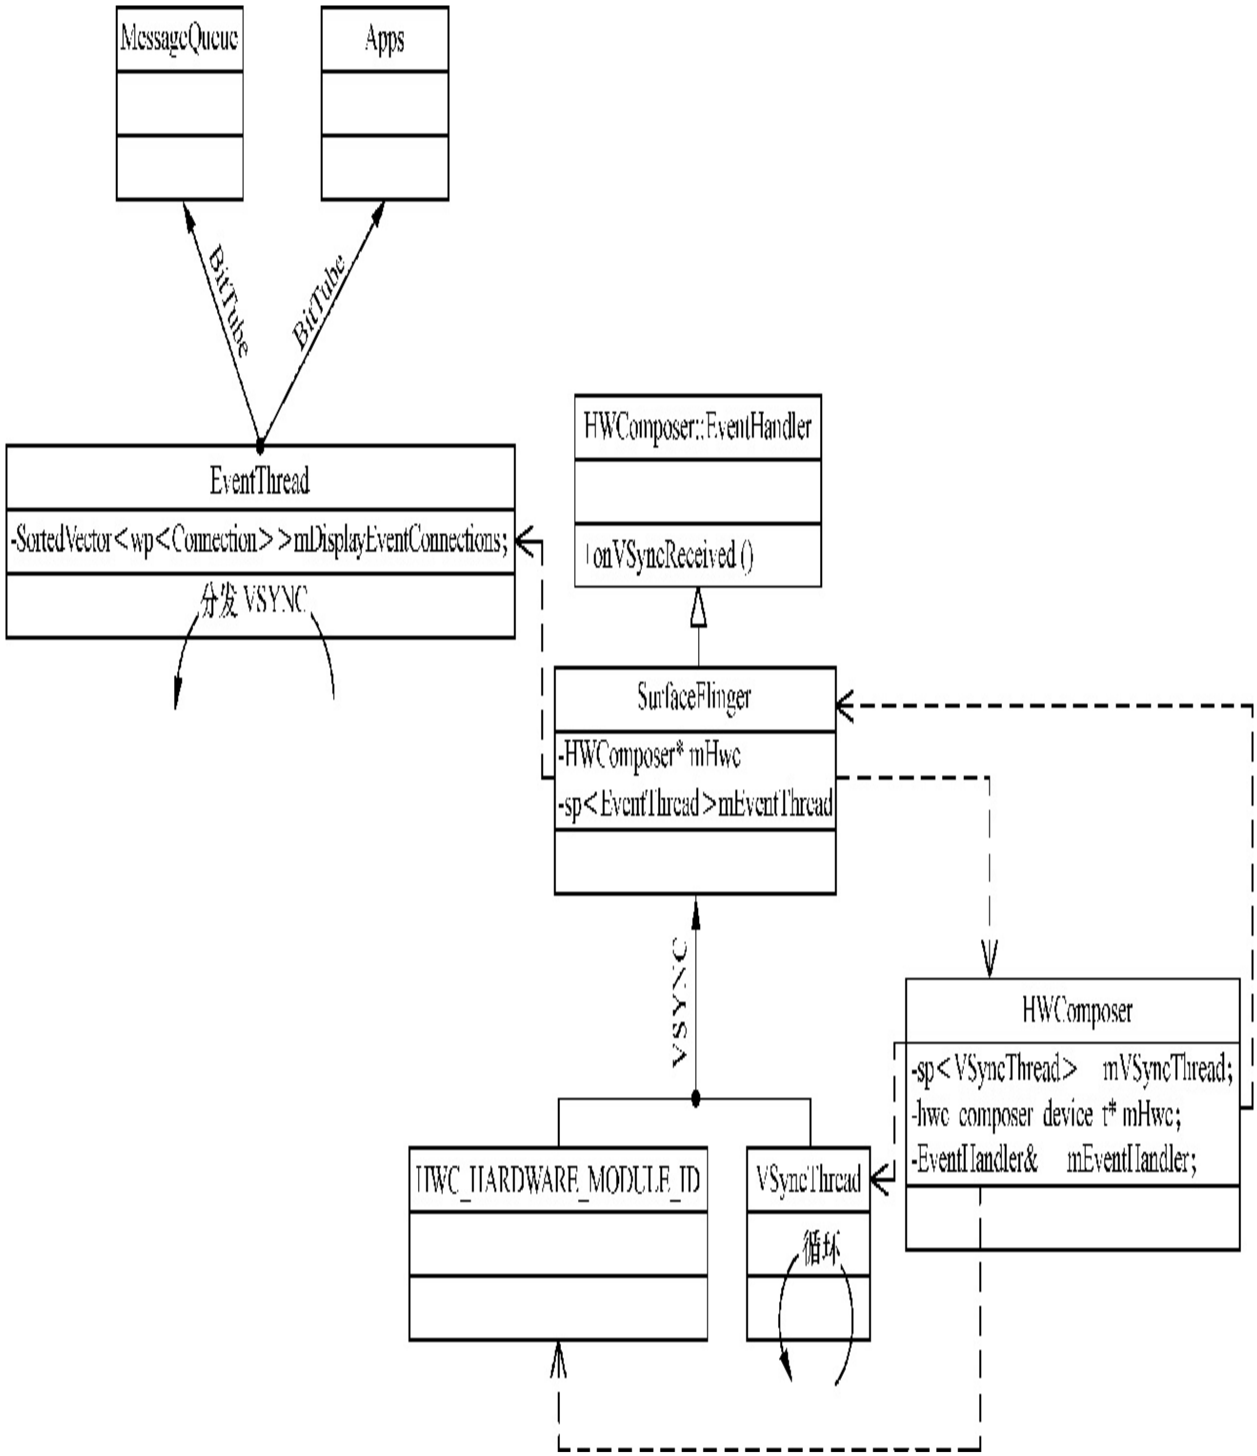

▲图9-36 VSync信号的产生与分发

整体逻辑关系相对复杂，建议大家在做源码分析时紧紧抓住下面两条线索。

- VSync信号的传递流向。
- 各个类的静态依赖关系，如SurfaceFlinger与EventThread，EventThread与Connection等类之间的联系。

9.7.2 VSync信号的处理

经过上一小节的分析，现在我们已经明白了系统是如何通过硬件设备或者软件模拟来产生VSync信号了，也明白了它的流转过程。VSync最终会被EventThread::threadLoop()分发给各监听者，如SurfaceFlinger进程中就是MessageQueue。

MessageQueue通过与EventThread建立一个Connection来监听事件，如图9-37所示。

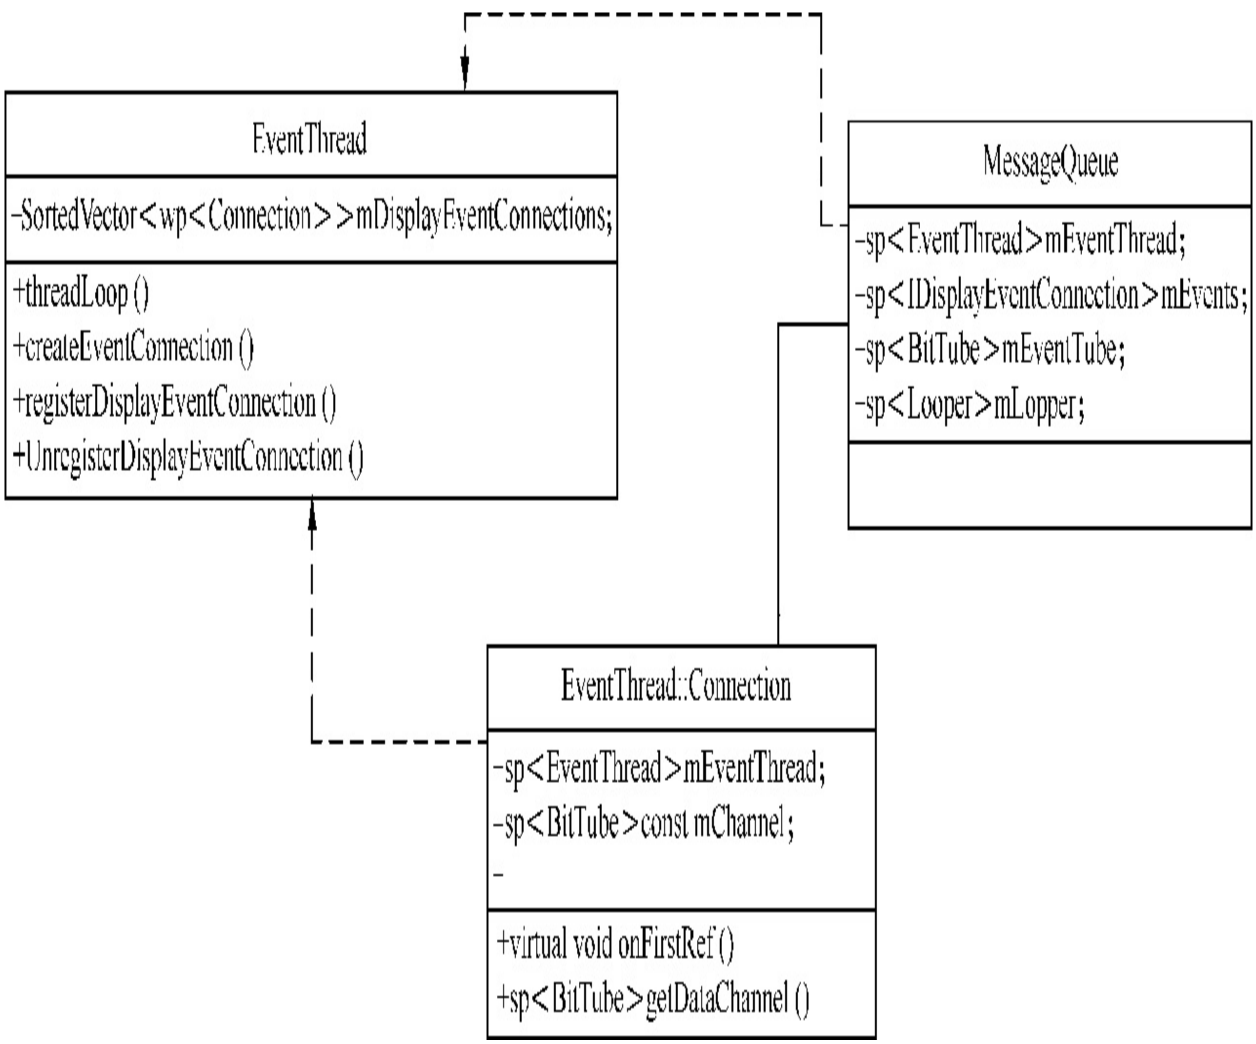

▲图9-37　Connection是EventThread与对事件感兴趣的对象的连接

对VSYNC等事件感兴趣的对象（如MessageQueue），首先要通过调用接口EventThread:: createEventConnection()来建立一个连接（应用进程是间接由SurfaceFlinger完成的），实际上就是生成了一个EventThread::Connection对象。这个对象将对双方产生如下影响。

- 当Connection::onFirstRef()时，即“连接”第一次被引用时，它会主动调用EventThread:: registerDisplayEventConnection()来把自己添加到EventThread的mDisplayEvent Connections中，这是保证事件发生后EventThread能找到符合要求的“连接”的关键一步。
- 当MessageQueue得到Connection后，它会马上调用getDataChannel来获得一个BitTube。从逻辑关系上看，Connection只是双方业务上的连接，而BitTube则是数据传输通道，各种Event信息就是通过这里传输的。

下面以MessageQueue为例来分析各个进程是如何与MessageThread进行交互的：

```
void MessageQueue::setEventThread(const sp<EventThread>& eventThr
{
    mEventThread = eventThread;
    mEvents = eventThread->createEventConnection(); //建立一个Conne
    mEventTube = mEvents->getDataChannel();//立即获取BitTube
    mLooper->addFd(mEventTube->getFd(),0,
                ALOOPER_EVENT_INPUT,MessageQueue::cb_eventRec
}
```

从扮演的角色来看，EventThread是Server，不断地往Tube中写入数据；而MessageQueue是Client，负责读取数据。可能有人会很好奇，MessageQueue如何得知有Event到来，然后去读取它呢？答案就是它们之间的数据读写模式采用的是Socket（AF_UNIX域）。

上面这个函数的末尾通过Looper添加了一个fd，这实际上就是Socket Pair中的一端。然后Looper将这个fd与其callback函数（即MessageQueue::cb_eventReceiver）加入全局的mRequests进行管理：

```
KeyedVector<int, Request> mRequests;
```

这个Vector会集中所有需要监测的fd。这样当Looper进行pollInner时，只要有事件需要处理，它就可以通过callback函数通知“接收者”。这里面的实现细节主要包括BitTube.cpp和Looper.cpp两个源文件，有兴趣的读者可以自行研究。

当Event发生后，MessageQueue:: cb_eventReceiver开始执行，进而调用eventReceiver。如果event的类型是DisplayEventReceiver::DISPLAY_EVENT_VSYNC，则正是我们想要监听的事件。这时会有两种情况：

```
if (buffer[i].header.type == DisplayEventReceiver::DISPLAY_EVENT_
{
#if INVALIDATE_ON_VSYNC
                mHandler->dispatchInvalidate();
#else
                mHandler->dispatchRefresh();
#endif
```

宏INVALIDATE_ON_VSYNC默认情况下被define为1，什么意思呢？

我们知道在把UI刷新到屏幕上（refresh）之前，各UI进程需要先准备好数据（invalidate）。那么SurfaceFlinger是在VSYNC来临时再做数据的准备工作，然后立即刷新到屏幕上；还是平常就开始准备，而当VSYNC来临时把数据刷新到屏幕上呢？

当INVALIDATE_ON_VSYNC为1时，程序执行前面的操作；否则就是第二种情况。

函数dispatchInvalidate和dispatchRefresh在SurfaceFlinger中的处理过程是有一定差异的，对比如表9-7所示。

因为signalRefresh最终的处理和handleMessageRefresh一样，可见INVALIDATE的情况下多执行了两个函数handleMessageTransaction和handleMessageInvalidate——它们分别用于处理“业务”（也就是客户端发起的对Layer属性的变更业务，后续小节有讲解）和数据Invalidate。

表9-7　INVALIDATE_ON_VSYNC的差异对比

dispatchInvalidate	dispatchRefresh

case MessageQueue::INVALIDATE: handleMessageTransaction(); handleMessageInvalidate(); signalRefresh();	case MessageQueue::REFRESH: handleMessageRefresh();

先来看看handleMessageRefresh所要做的工作（这也是我们后续几个小节的阐述重点）：

```
void SurfaceFlinger::handleMessageRefresh() {
    ATRACE_CALL();
    preComposition();//合成前的准备
    rebuildLayerStacks();//重新建立Layer堆栈
    setUpHWComposer();//HWComposer的设定
    doDebugFlashRegions();
    doComposition();//正式的合成工作
    postComposition();//合成后期工作
}
```

虽然Jelly Bean的几个版本（4.1～4.3）中，对于SurfaceFlinger渲染UI的处理过程改动很大，但不可否认的是，目前4.3系统已经达到了比较好的状态——不论是从代码风格还是逻辑关系上，相比前两个版本都有很大程度的提高。

整个UI合成过程包括了如下几个函数：

- preComposition；
- rebuildLayerStacks；
- setUpHWComposer；
- doDebugFlashRegions；
- doComposition；
- postComposition。

上述这些函数再加上handleMessageTransaction、

handleMessageInvalidate，基本涵盖了SurfaceFlinger的所有功能。接下来的几个小节我们将详细分析它们。

9.7.3 handleMessageTransaction

函数handleMessageTransaction在做了简单的判断后，直接调用了handleTransaction。接着handleTransaction首先获取mStateLock锁，然后才能进一步调用handleTransactionLocked，最后再将mHwWorkListDirty（后面小节会看到这个变量的作用）置为true。

显然后一个handleTransactionLocked才是真正处理业务的地方，它的具体工作分为两部分，即traversal（对应eTraversalNeeded）和transaction（对应eTransactionNeeded）：

```
void SurfaceFlinger::handleTransactionLocked(uint32_t transaction
{
    const LayerVector& currentLayers(mCurrentState.layersSortedBy
    const size_t count = currentLayers.size();
    if (transactionFlags & eTraversalNeeded) {//Part1. 是否需要trav
      for (size_t i=0 ; i<count ; i++) {//逐个layer来处理
        const sp<Layer>& layer(currentLayers[i]);
       uint32_t trFlags = layer->getTransactionFlags(eTransaction
                                                              否
            if (!trFlags) continue;//如果不需要的话，直接进入下一轮循环
            const uint32_t flags = layer->do Transaction(0);/*由各
                                                              做
            if (flags & Layer::eVisibleRegion)//各Layer计算可见区域
                mVisibleRegionsDirty = true;//可见区域发生变化
        }
    }
    if (transactionFlags & eDisplayTransactionNeeded) {
        …//代码略
    }
    if (transactionFlags & (eTraversalNeeded|eDisplayTransactionN
        …//代码略
    }
    …//Part2. SurfaceFlinger内部所产生的“Transaction”的处理
    commitTransaction();//提交结果
```

TransactionFlags分为3种类别，即：

```
enum {
    eTransactionNeeded        = 0x01,
    eTraversalNeeded          = 0x02,
```

```
    eDisplayTransactionNeeded = 0x04,
    eTransactionMask          = 0x07//用于取值
};
```

上述代码段的Part1部分就是围绕这3种Flag展开的。因为各Flag的处理过程基本上相似，限于篇幅我们只选取eTraversalNeeded为例来讲解。

Part1. 处理各Flags（以eTraversalNeeded为例）

先来看eTraversalNeeded的处理。从名称可以看出，它表示当前需要一个“Traversal”的操作，即遍历所有Layers。

SurfaceFlinger中记录当前系统中layers状态的有两个全局变量，分别是：

```
State                   mDrawingState;
State                   mCurrentState;
```

前者是上一次“drawing”时的状态，而后者则是当前状态。这样我们只要通过对比这两个State，就知道Layer在两次状态中发生了什么变化，从而采取相应的措施。它们内部都包含了一个LayerVector类型的layersSortedByZ成员变量，从变量名可以看出是所有Layers按照Z-order顺序排列而成的Vector。

所以我们可以通过mCurrentState.layersSortedByZ来遍历所有Layers，然后对其中需要执行transaction的Layer调用内部的doTransaction()。显然，并不是每个Layer在每次handleTransactionLocked中都需要调用doTransaction——判断的标准就是Layer::getTransactionFlags返回的标志中是否指明了eTransactionNeeded。大家要注意SurfaceFlinger和Layer都有一个mTransactionFlags变量，不过含义不同。另外，Layer对象中也同样有mCurrentState和mDrawingState，却属于完全不同的Struct数据结构。其对比如图9-38所示。

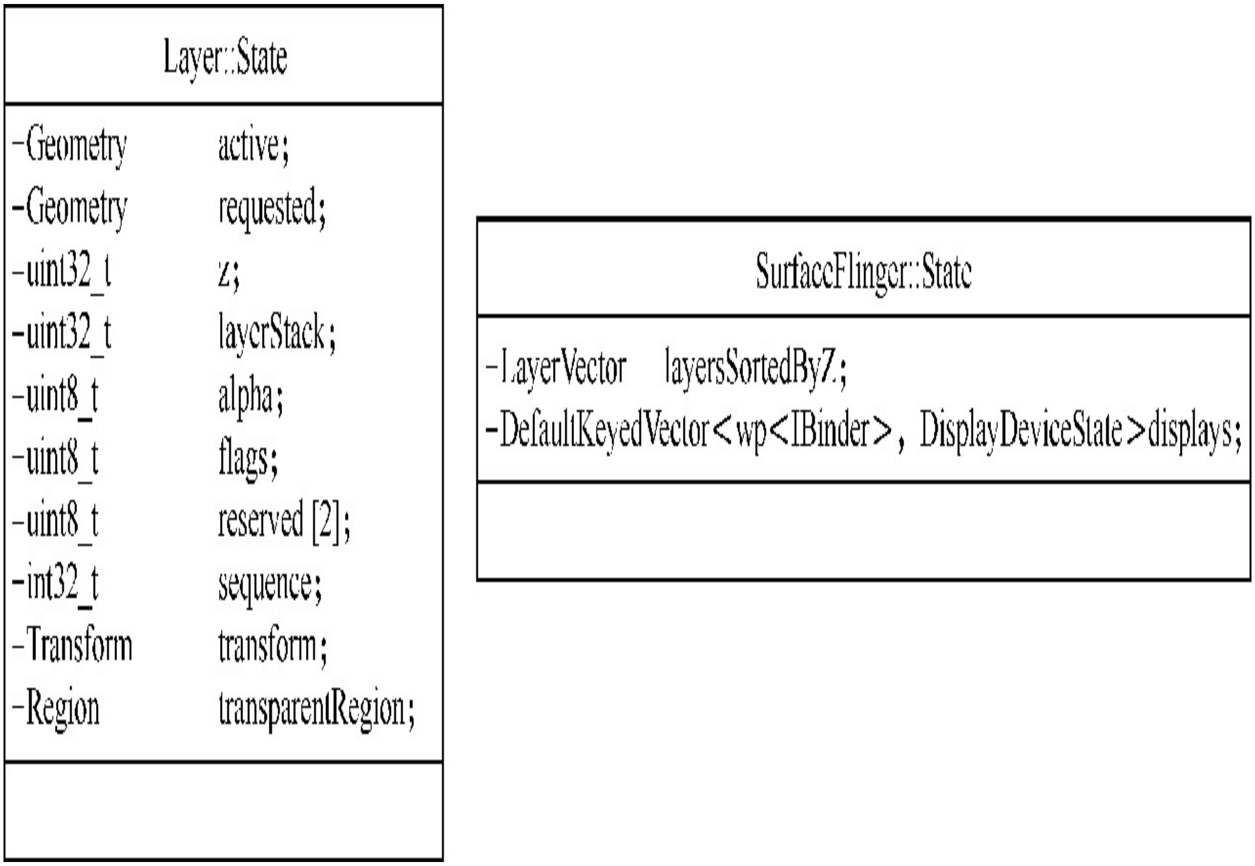

▲图9-38　两个State结构体对比

为了理解各个Layer究竟在doTransaction中做了些什么，我们先穿插分析下它的实现：

```
uint32_t Layer::doTransaction(uint32_t flags)
{…
    const Layer::State& front(drawingState());/*mDrawingState*/
    const Layer::State& temp(currentState());/*mCurrentState*/

    const bool sizeChanged = (temp.requested.w != front.requested
    h != front.requested.h);
    if (sizeChanged) {//尺寸发生变化
        …
        mSurfaceFlingerConsumer->setDefaultBufferSize(temp.reques
                                                      temp.reques
    }
    …
    if (front.active != temp.active) {//需要重新计算可见区域
        flags |= Layer::eVisibleRegion;
    }
```

```
    if (temp.sequence != front.sequence) {//什么是sequence?
        flags |= eVisibleRegion;//也需要重新计算可见区域
        this->contentDirty = true;
        const uint8_t type = temp.transform.getType();
        mNeedsFiltering = (!temp.transform.preserveRects() || (ty
    }
    commitTransaction();
    return flags;
}
```

首先判断Layer的尺寸是否发生了改变（sizeChanged变量），即当前状态（temp）中的宽/高与上一次状态（front）一致与否。假如size发生了变化，我们调用mSurfaceFlingerConsumer->setDefaultBufferSize()来使它生效。其中mSurfaceFlingerConsumer在前几个小节已经详细分析过，若不清楚可以回头看看。

函数setDefaultBufferSize()改变的是内部的mDefaultWidth和mDefaultHeight两个默认的宽高值。当我们调用requestBuffers()请求Buffer时，如果没有指定width和height（值为0），BufferQueue就会使用这两个默认配置。

接下来的难点就是理解sequence。这个变量是一个int值，当Layer的position，z-order，alpha，matrix，transparent region，flags，crop等一系列属性发生变化时（这些属性的设置函数都以setXXX开头，如setCrop，setFlags），mCurrentState::sequence就会自增。因而当doTransaction时，它和mDrawingState::sequence的值就不一样了。相比于每次属性变化时都马上做处理，这样的设计是合理的。因为它在平时只收集属性的变化，直到特定的时刻（VSYNC信号产生时）才做统一处理。一方面，这节约了系统资源；另一方面，如果属性频繁变化，会给整个画面带来不稳定感，而采用这种方式就能规避这些问题。

仔细观察Layer的doTransaction()实现，我们可以大致得出它的目的，就是通过分析当前与上一次的状态变化，来制定下一步的操作——比如是否要重新计算可见区域（eVisibleRegion）、是否需要重绘（contentDirty）等。

这些操作有的是要由SurfaceFlinger统一部署的，因而通过函数的返回值flags传递给SurfaceFlinger，如eVisibleRegion；有些则属于Layer的“家务”，因而只要内部做好标记即可。

最后，commitTransaction()把mCurrentState赋值给mDrawingState，这样它们两个的状态就又一样了。在下一轮doTransaction()前，mCurrentState又会随着属性的变更（引起变更的情况很多，如UI程序客户端主动发起的申请）而产生变化，如此循环往复。

这样Layer::doTransaction()函数就结束了，带着flags值返回到前面的SurfaceFlinger:: handleTransactionLocked()中。一旦某个Layer明确表明可见区域发生了改变（eVisibleRegion），SurfaceFlinger就会将其mVisibleRegionsDirty设为true，这个标志将影响后续的操作。

Part2.“内务”处理

完成当前系统中所有Layer的遍历后，SurfaceFlinger就进入自己的“内务”处理了，即handleTransactionLocked()源码中的第二部分。我们在代码中列出了它需要完成的工作，即：

- 新增Layer

与上一次处理时相比，系统可能有新增的Layer。我们只要对比两个State中的Layer队列数目是否一致就可以得出结论。假如Layer数量有增加，可见区域需要重新计算，我们将mVisibleRegionsDirty置为true。

- 移除Layer

和上面的情况类似，有些Layer也可能被移除了。针对这种情况，我们也需要重新计算可见区域。可是怎么知道哪些Layer被移除了呢？有一个简单的办法就是比较两个State中的layersSortedByZ——假如一个Layer在上一次的mDrawingState中还有，到了这次mCurrentState找不到了，那么就可以认定它被removed了。我们需要计算这些“被剔除图层”的可见区域，因为一旦Layer被移除，则意味着被它遮盖的区域就有可能重新显露出来。

在handleTransactionLocked()末尾，它也调用了commitTransaction()来结束整个业务处理。

另外，SurfaceFlinger还需要通知所有被移除的Layer，相应的callback函数是onRemoved()。Layer在得到这一消息后，就知道它已经被SurfaceFlinger剔除了。最后，唤醒所有正在等待Transaction结束的线程：

```
mTransactionCV.broadcast();
```

SurfaceFlinger:: handleTransaction ()的流程如图9-39所示。

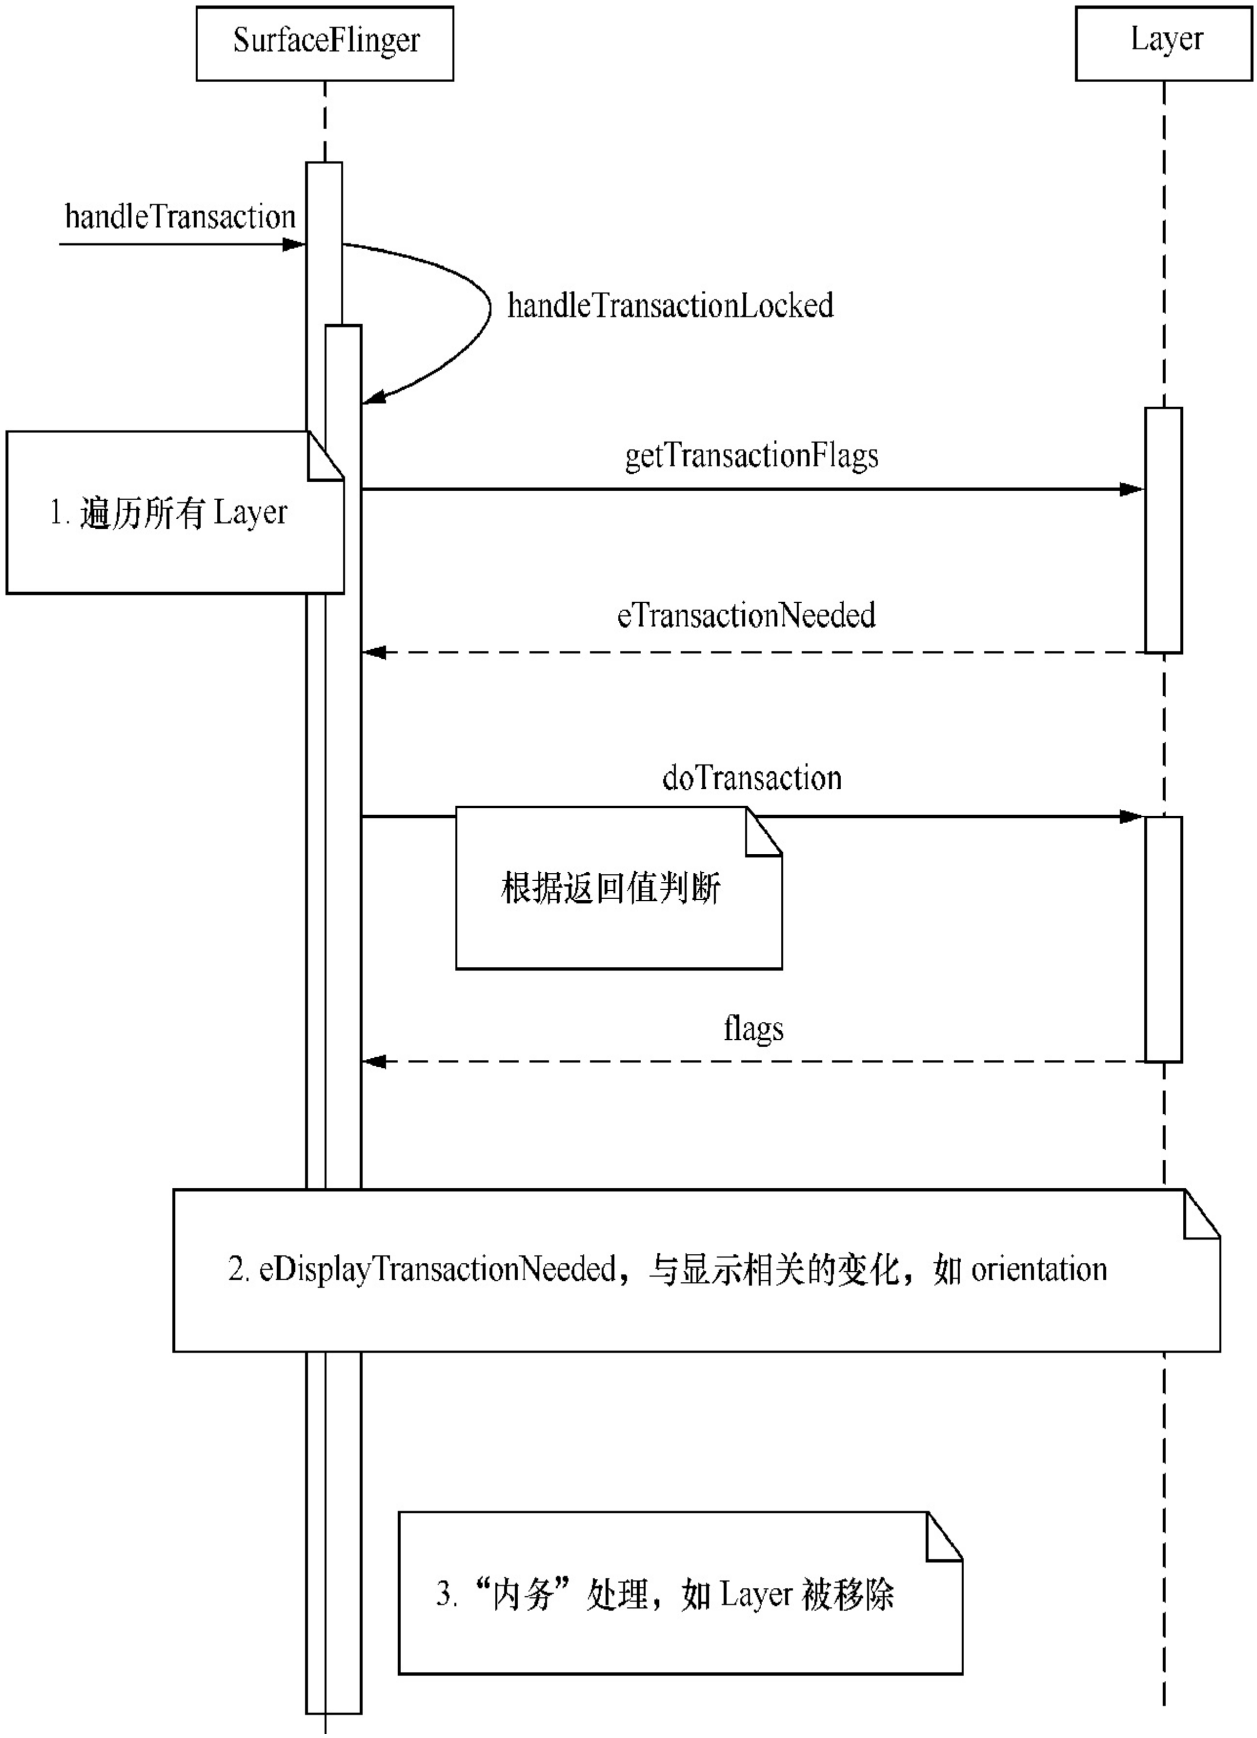

SurfaceFlinger
Layer
handleTransaction
handleTransactionLocked
1. 遍历所有 Layer
getTransactionFlags
eTransactionNeeded
doTransaction
根据返回值判断
flags
2. eDisplayTransactionNeeded，与显示相关的变化，如 orientation
3. “内务”处理，如 Layer 被移除

▲图9-39 handleTransaction流程图

9.7.4 “界面已经过时/无效，需要重新绘制”——handleMessageInvalidate

Invalidate的字面意思是“使无效”，在不少窗口系统中都被用来表示“界面已经过时/无效，需要重新绘制”。在SurfaceFlinger中，与Invalidate关系最直接的是Buffer数据，因而handleMessageInvalidate实际上只是简单地调用了另一个函数handlePageFlip。

PageFlip可以理解为“翻页”。从字面意思上来理解，它的确与“图层缓冲区”有关系——因为是多缓冲机制，那么在适当的时机就需要做“翻页”的动作。核心源码如下：

```
void SurfaceFlinger::handlePageFlip()
{
    Region dirtyRegion;
    bool visibleRegions = false;
    const LayerVector& currentLayers(mDrawingState.layersSortedBy
    const size_t count = currentLayers.size();
    for (size_t i=0 ; i<count ; i++) {
        const sp<Layer>& layer(currentLayers[i]);
        const Region dirty(layer->latchBuffer(visibleRegions));/*
        const Layer::State& s(layer->drawingState());
        invalidateLayerStack(s.layerStack, dirty);//Step2. 更新Dis
    }
    mVisibleRegionsDirty |= visibleRegions;
}
```

Step1@SurfaceFlinger::handlePageFlip，通过latchBuffer分别锁定各Layer当前要处理的缓冲区。源码作者用了一个有趣的词“latch”，形象地表达了“把门闩上，锁住Buffer”的意图。可想而知，这个函数一定与BufferQueue有直接联系：

```
Region Layer::latchBuffer(bool& recomputeVisibleRegions)
{…
    Region outDirtyRegion;
    if (mQueuedFrames > 0) {…//有需要处理的Frame
        const bool oldOpacity = isOpaque();
        sp<GraphicBuffer> oldActiveBuffer = mActiveBuffer;
```

```
        if (android_atomic_dec(&mQueuedFrames) > 1) {
            mFlinger->signalLayerUpdate();
        }
        …//定义一个名为“Reject”的struct，代码略
        Reject r(mDrawingState, currentState(), recomputeVisibleR
        if (mSurfaceFlingerConsumer->updateTexImage(&r) != NO_ERR
            …//异常处理，并结束函数
        }
        mActiveBuffer = mSurfaceFlingerConsumer->getCurrentBuffer
        …
        glTexParameterx(GL_TEXTURE_EXTERNAL_OES, GL_TEXTURE_WRAP_
        glTexParameterx(GL_TEXTURE_EXTERNAL_OES, GL_TEXTURE_WRAP_
        const Layer::State& front(drawingState());
        Region dirtyRegion(Rect(front.active.w, front.active.h));
        outDirtyRegion = (front.transform.transform(dirtyRegion))
    }
    return outDirtyRegion;
}
```

Layer中继承了FrameAvailableListener，专门用于“监听”onFrameAvailable。因而当BufferQueue中的一个BufferSlot被queued后，它会通知这个Listener，进而调用所属Layer的onFrameQueued——这个函数会增加mQueuedFrames的计数，并且向SurfaceFlinger发出一个INVALIDATE信号（signalLayerUpdate）。

如果当前没有任何queued buffer，latchBuffer什么都不用做；如果当前有多个mQueuedFrames，除了正常处理外，我们还需要另外调用signalLayerUpdate来组织一次新的invalidate。

Layer中持有一个SurfaceFlingerConsumer对象（成员变量mSurfaceFlingerConsumer），用于管理BufferQueue。根据前几个小节我们对BufferQueue状态迁移的分析，一旦SurfaceFlinger（消费者）需要对某个buffer进行操作，首先应该accquire它——这个动作被封装在SurfaceFlinger Consumer::updateTexImage中。除此之外，这个函数还需要根据Buffer中的内容来更新Texture，稍后再做详细分析。

在latchBuffer内部定义了一个Reject结构体，并作为函数参数传递给updateTexImage。后者在acquire到buffer后，会主动调用Reject::reject()来判断这个缓冲区是否符合SurfaceFlinger的要求。如果updateTexImage成功，Layer就可以更新mActiveBuffer了，即当前活跃的缓冲区（每个Layer对应32个BufferSlot）；以及其他一系列相关内部成员变量，如mCurrentCrop、mCurrentTransform等，这部分源

码省略。

纹理贴图还涉及很多细节的配置，比如说纹理图像与目标的尺寸大小有可能不一致，这种情况下怎么处理？或者当纹理坐标超过[0.0,1.0]范围时，应该怎么解决？这些具体的处理方式都可以通过调用glTexParameterx(GLenum target, GLenum pname, GLfixed param)来配置。函数的第二个参数是需要配置的对象类型（比如GL_TEXTURE_WRAP_S和GL_TEXTURE_WRAP_T分别代表两个坐标维）；第三个参数param就是具体的配置：

```
status_t SurfaceFlingerConsumer::updateTexImage(BufferRejecter* r
{…
    Mutex::Autolock lock(mMutex);
    …
    BufferQueue::BufferItem item;
    err = acquireBufferLocked(&item);//acquire一个buffer
    int buf = item.mBuf;
    if (rejecter && rejecter->reject(mSlots[buf].mGraphicBuffer,
{                                                                   //这个b
        releaseBufferLocked(buf, EGL_NO_SYNC_KHR);
        return NO_ERROR;//注意，reject返回false表示“接受”;否则才是“拒绝
    }

    // 生成Texture
    err = releaseAndUpdateLocked(item);
    …
    return err;
}
```

这个函数比较长，我们只保留了最核心的部分。它的目标是更新Layer的纹理（Texture），分为如下几步。

（1）Acquire一个需要处理的Buffer。根据前面对Buffer状态迁移的分析，当消费者想处理一块Buffer时，首先要向BufferQueue做acquire申请。那么，BufferQueue怎么知道当前要处理的是哪一个Buffer呢？这是因为其内部维护有一个Fifo先入先出队列。一旦有Buffer被enqueued后，就会被压入队尾；每次acquire就从队头取最前面的元素进行处理，完成之后再将其从队列移除。

（2）Acquire到的Buffer封装在BufferItem中，item.mBuf代表它在BufferSlot中的序号。假如mEGLSlots[buf].mEglImage当前不为空（EGL_NO_IMAGE_KHR），则需要先把旧的image销毁

（eglDestroyImageKHR）。

（3）SurfaceFlinger有权决定updateTexImage得到的Buffer是否为合法有效的（比如说size是否正确），这是通过updateTexImage(BufferRejecter* rejecter)中的rejecter对象来完成的。BufferRejecter实现了一个reject接口，用于验证前面acquire到的buffer是否符合SurfaceFlinger的要求。

（4）接下来就可以生成Texture了，内部实现中需要分别调用glBindTexture和glEGLImage TargetTexture2DOES。后一个函数是OpenGL ES中对glTexImage2D的扩展（因为在嵌入式环境下如果直接采用glTexImage2DI，一旦图片很大时会严重影响执行速度，而经过扩展后的glEGLImageTargetTexture2DOES可以避免这个问题）。这个接口是和eglCreateImageKHR配套使用的，被封装在前面的createImage中。不了解这些函数用法的读者希望能自行查询OpenGL ES技术文档。

（5）消费者一旦处理完Buffer，就可以将其release了。此后这个Buffer就又恢复到FREE状态，以供生产者再次dequeue使用之后，我们需要更新GLConsumer（SurfaceFlingerConsumer的父类）中的各成员变量，包括mCurrentTexture、mCurrentTextureBuf等。

具体如图9-40所示。

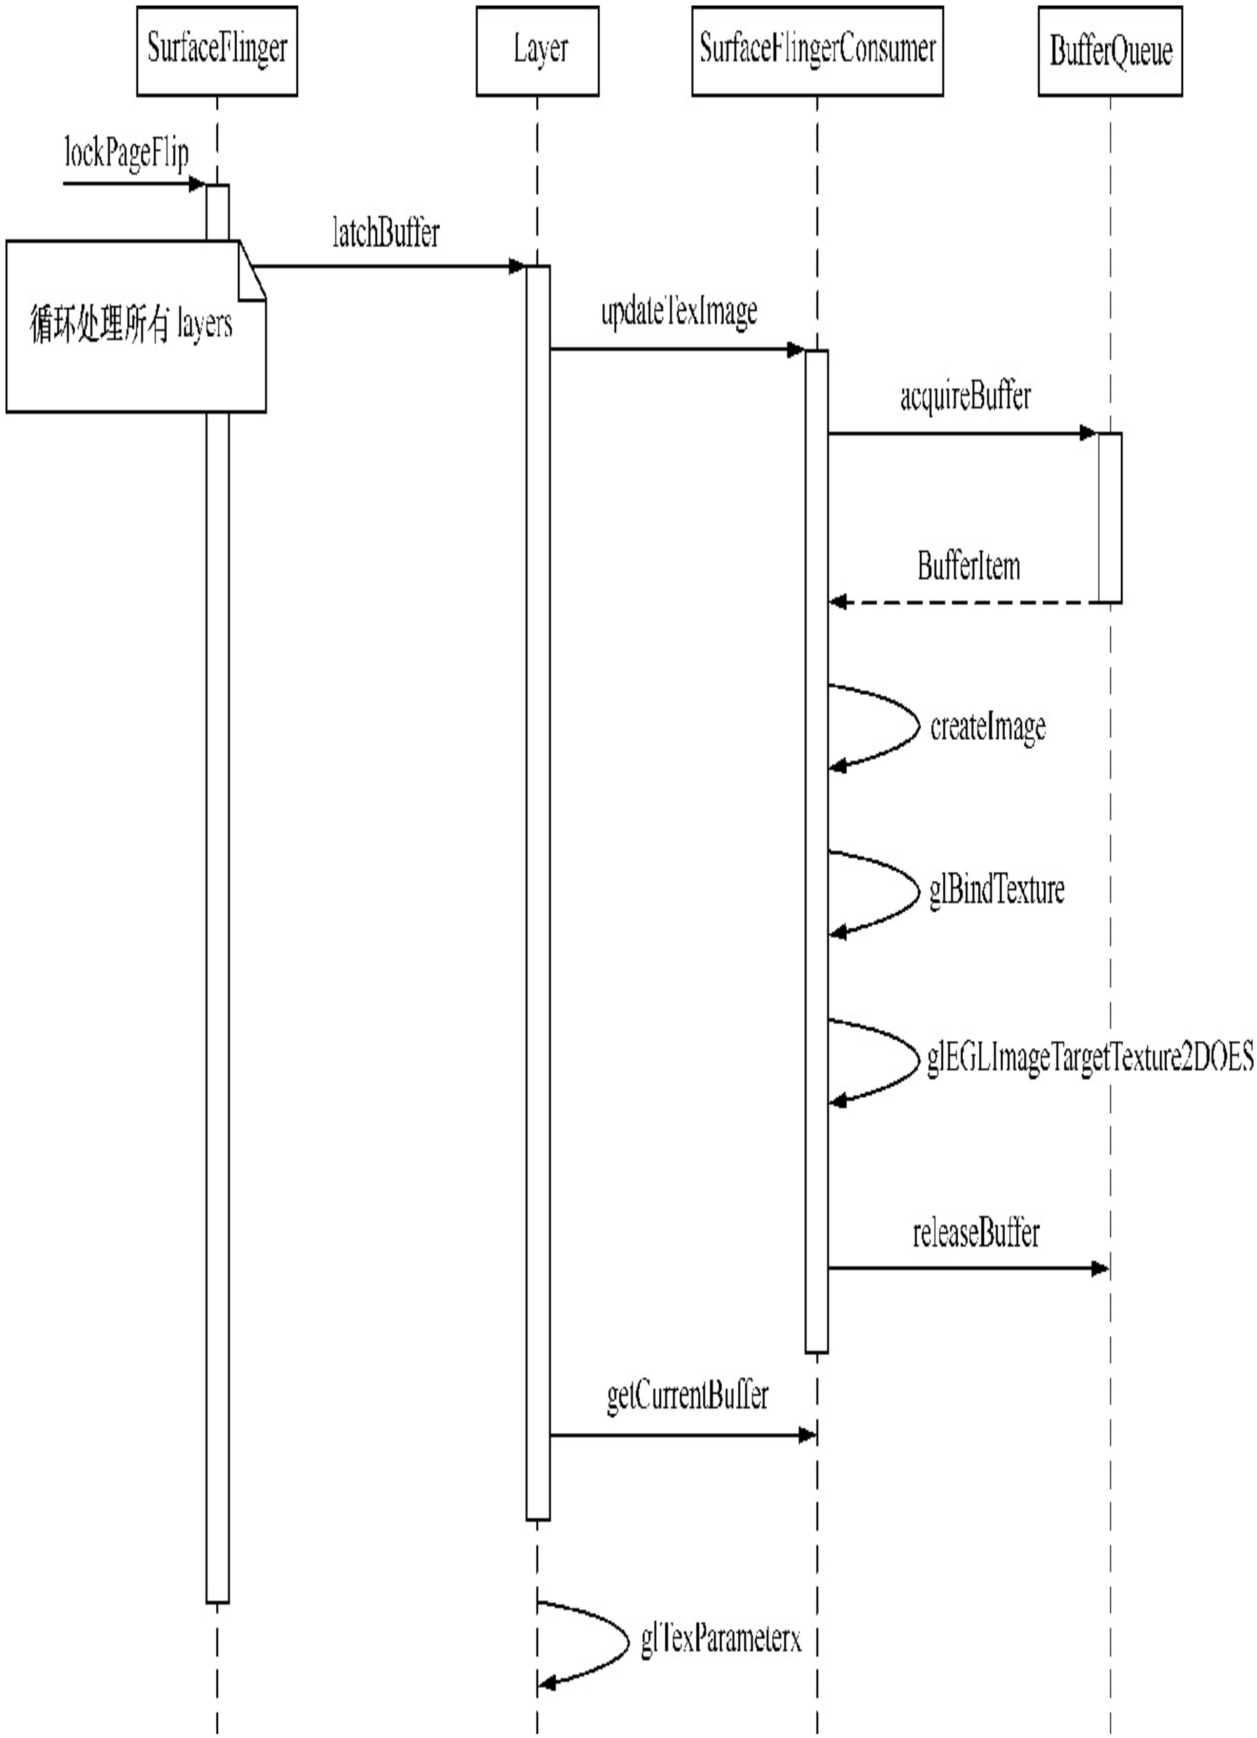

SurfaceFlinger
Layer
SurfaceFlingerConsumer
BufferQueue
lockPageFlip
latchBuffer
循环处理所有 layers
updateTexImage
acquireBuffer
BufferItem
createImage
glBindTexture
glEGLImageTargetTexture2DOES
releaseBuffer
getCurrentBuffer
glTexParameterx

▲图9-40　latchBuffer流程图

Step2@SurfaceFlinger::handlePageFlip，通过invalidateLayerStack来更新各DisplayDevice中的dirtyRegion。内部实现比较简单，读者可以自行分析。

9.7.5　合成前的准备工作——preComposition

从字面来理解就是“预合成”——即合成前的准备工作。在分析preComposition的具体工作前，我们有必要先了解下VSync Rate。

IDisplayEventConnection中提供了与VSync Rate有关的两个接口：

```
    virtual void setVsyncRate(uint32_t count) = 0;
    virtual void requestNextVsync() = 0;    // asynchronous
```

它们之间具有互斥的关系：当setVSyncRate设置了数值1，表示每个VSync信号都要报告；数值2表示隔一个VSync报告一次；数值0则表示不报告任何VSync，除非有人主动调用了requestNextVsync。同理，除非setVSyncRate设置的值为0，否则调用requestNextVsync来安排下一次VSync会被认为是无效的。

接下来我们看看preComposition的实现：

```
void SurfaceFlinger::preComposition()
{
    bool needExtraInvalidate = false;
    const LayerVector&currentLayers(mDrawingState.layersSortedByZ
    const size_t count = currentLayers.size();//Layer数量
    for (size_t i=0 ; i<count ; i++) {
        if (currentLayers[i]->onPreComposition()) {//调用每个Layer
            needExtraInvalidate = true;
        }
    }
    if (needExtraInvalidate) {
        signalLayerUpdate();//这个函数是做什么的?
    }
}
```

这个函数的逻辑比较简单，它会遍历系统中记录的所有Layers，并

一一调用它们的onPre Composition。换句话说，就是给每个人机会来做“准备工作”。那么，需要做什么样的准备呢？

```
bool Layer::onPreComposition() {…
    return mQueuedFrames> 0;
}
```

可见当onPreComposition的返回值为true时，表示mQueuedFrames>0；否则就是false。结合SurfaceFlinger::preComposition中的判断，只要有一个Layer中存在被Queued的Frames，那么needExtraInvalidate都会变成true。这时就会触发如下的函数调用流程：

SurfaceFlinger::signalLayerUpdateMessageQueue::invalidateI[
NextVsync EventThread::requestNextVsync：

```
void EventThread::requestNextVsync(const sp<EventThread::Connecti
    Mutex::Autolock _l(mLock);
    if (connection->count < 0) {//<0说明disabled
        connection->count = 0;//=0说明还有可以接收一次event
        mCondition.broadcast();//通知EventThread，有人对VSync感兴趣
    }
}
```

注意

这里的count是Connection类的成员变量。它的含义如下：

- ⩾1时

  可以连续性地接收事件。

- =0时

  一次性事件（还未接收）。

- =-1时

  可以认为事件接收被disabled了。

所以在requestNextVsync中，如果connection->count<0，会被重新赋值为0，代表这个connection可以接收一次事件。

最后，requestNextVsync会调用mCondition.broadcast()，那么是谁在等待呢？

没错，还是EventThread。我们知道EventThread::threadLoop会不断地调用waitForEvent来等待Event。这个函数的内部还有一个重要的判断，即当前是否有对VSync信号感兴趣的人（基于所有Connection中的count状态来判断）：有的话才能正常返回，否则调用：

```
mCondition.wait(mLock);
```

进入等待，直到有人来唤醒它。

9.7.6 可见区域——rebuildLayerStacks

经过preComposition后，SurfaceFlinger::handleMessageRefresh接着会调用rebuildLayerStacks。这个函数负责rebuild所有可见的Layer(Visible Layer)——核心思想就是计算有哪些Layer是可见的及它们的可见区域。源码实现如下：

```
void SurfaceFlinger::rebuildLayerStacks() {
    if (CC_UNLIKELY(mVisibleRegionsDirty)) {…
        mVisibleRegionsDirty = false;//重置变量
        invalidateHwcGeometry();//将mHwWorkListDirty置为true,后续会

        const LayerVector& currentLayers(mDrawingState.layersSort
        for (size_t dpy=0 ; dpy<mDisplays.size() ; dpy++) {/*Step
            Region opaqueRegion;//不透明区域
            Region dirtyRegion;//“脏”区域
            Vector< sp<Layer>> layersSortedByZ;//最终排序后的可见Lay
            const sp<DisplayDevice>& hw(mDisplays[dpy]);/*每一个Di
            const Transform& tr(hw->getTransform());//Transform变
            const Rect bounds(hw->getBounds());//Display的区域
            if (hw->canDraw()) {//当前这个Display是否可以绘制
                SurfaceFlinger::computeVisibleRegions(currentLaye
                      hw->getLayerStack(), dirtyRegion, opaqueReg
                const size_t count = currentLayers.size();//当前La
                for (size_t i=0 ; i<count ; i++) {/*Step3.逐个计算
                    const sp<Layer>& layer(currentLayers[i]);
                    const Layer::State& s(layer->drawingState());
                    if (s.layerStack == hw->getLayerStack()) {//此
```

```
                        Region drawRegion(tr.transform(layer->vis
                        drawRegion.andSelf(bounds);
                        if (!drawRegion.isEmpty()) {//如果绘制区域不
                            layersSortedByZ.add(layer);
                        }
                    }
                }
            }
               /*Step4. 将前述的计算结果保存到hw中*/
            hw->setVisibleLayersSortedByZ(layersSortedByZ);
            hw->undefinedRegion.set(bounds);
            hw->undefinedRegion.subtractSelf(tr.transform(opaqueR
            hw->dirtyRegion.orSelf(dirtyRegion);
        }
    }
}
```

Step1@SurfaceFlinger::rebuildLayerStacks。前面说过，系统的Display可能不止一个——它们都存储在mDisplays中，rebuildLayerStacks需要逐个处理这些Display。这个函数中涉及的与Display有关的全局属性包括：

- Transform mGlobalTransform

即整个Display都需要做的Transform。换句话说，各个Layer也可以有自己的Transform。

- int mDisplayWidth;

int mDisplayHeight;

即Display的宽和高，上述代码段中的bounds变量（hw->getBounds()）得到的是：

Rect(mDisplayWidth, mDisplayHeight)。

Step2@SurfaceFlinger::rebuildLayerStacks，调用computeVisibleRegions。这个函数将根据所有Layer（即currentLayers）的当前状态，计算出两个重要变量。

- dirtyRegion

“脏”区域，也就是需要被重新绘制的区域。

- opaqueRegion

不透明区域，它会对Z-Ordered的Layers产生影响。因为排在前面的Layer的不透明区域可能会遮挡其后的Layer。

函数computeVisibleRegions的源码实现很长，我们放在后面单独分析。

Step3@SurfaceFlinger::rebuildLayerStacks。计算出Visible Regions后，程序需要进一步确定各Layer需要被绘制的区域（drawRegion）。

首先要明白系统中可用的Display不止一个，但所有的Layers却都是通过mDrawingState. layersSortedByZ来记录的，显然系统需要一个机制来区别各Layer的归属方——这就是LayerStack的作用。每个Display都有一个独立的“标志”，作为SurfaceFlinger管理它们的依据。

所以在第二个for循环中，需要先判断下s.layerStack是否等于hw->getLayerStack：是的话才需要进一步处理。变量drawRegion的计算过程分为如下两步。

（1）对Layer中的visibleNonTransparentRegion按照整个Display的Transform要求进行变换。其中visibleNonTransparentRegion如其名所示，代表了Layer的“可见不透明区域”，是由前面的computeVisibleRegions计算出来的。

（2）在上述区域drawRegion的基础上考虑bounds，即整个Display的区域限制。

最后得到的drawRegion如果不为empty，那么说明该Layer在此次UI刷新过程中是需要被重新绘制的，因而把它加入layersSortedByZ中。我们对Layer的处理过程是按照Z-Order顺序来执行的，所以在把它们依次加入layersSortedByZ时，也同样已经“SortedByZ-Order”了。

Step4@SurfaceFlinger::rebuildLayerStacks。这一步将前面的计

算结果即layersSortedByZ，opaqueRegion等保存到hw中，这些数据对后面的合成起到了关键的作用。

接下来我们专门分析下computeVisibleRegions的实现，其中Dirty区域的计算过程是关注的重点。读者可以先思考下，如果让我们来写这个函数，该如何实现呢？

把问题重新明确下：已知当前所有的Layers（按照Z-Order排序），如何计算它们的DirtyRegion与OpaqueRegion？

（1）既然Layers是Z-Order排序的，那么我们在处理各个Layer时是按照递增还是递减的顺序来执行呢？显然是递减，因为Z-Order值大的更靠近“用户”。换句话说，如果我们计算出某Layer的OpaqueRegion，那么后面比它Z-Order小的Layer的对应区域根本就不需要考虑——从用户视角来看，这部分区域一定会被“遮挡”。

（2）计算DirtyRegion的前提是获得该图层的可见区域，因为可见区域之外的“脏”区域是没有意义的。图层中什么样的区域是可见的呢？至少需要考虑以下几点。

- Z-Order

各Layer的Z-Order无疑是第一要素。因为排在越前面的图层，其获得曝光的概率越大，可见的区域也可能越大，如图9-41所示。

前面说过，计算可见性时是按照Z-Order由大而小的顺序进行的。假如一个Layer的某个区域被确定为可见且不透明，那么与之相对应的其下面的所有Layer区域都会被遮盖而不可见。

- 透明度

虽然越前面的Layer优先级越高，但这并不代表后面的“图层”完全没有机会。只要前一个Layer不是完全不透明（透明或者半透明）的，那么从理论上来讲用户就应该能“透过”这部分区域看到后面的内容。

- Layer大小

与透明度一样，“图层”大小也直接影响到其可见区域。因为每个Layer都是有大有小的，即便前一个Layer是完全不透明的，但只要它的尺寸没有达到“满屏”，那么比它Z-Order小的“图层”还是有机会显示出来的。这也是我们需要考虑的因素之一。

综合上面的几点分析，我们大概能制定出计算Layer可见区域的逻辑步骤。

- 按照Z-Order逐个计算各Layer的可见区域，结果数据记录在LayerBase:: visibleRegion Screen中。

- 对于Z-Order值最大的Layer，显然没有其他“图层”会遮盖它。所以它的可见区域（visibleRegion）应该是（当然，前提是这个Layer没有超过屏幕区域）自身的大小再减去完全透明的部分（transparentRegionScreen），由此计算出来的结果我们称之为aboveCoveredLayers。这个变量应该是全局的，因为它需要被传递到后面的Layers中，然后不断地做累积运算，直到覆盖整个屏幕区域。

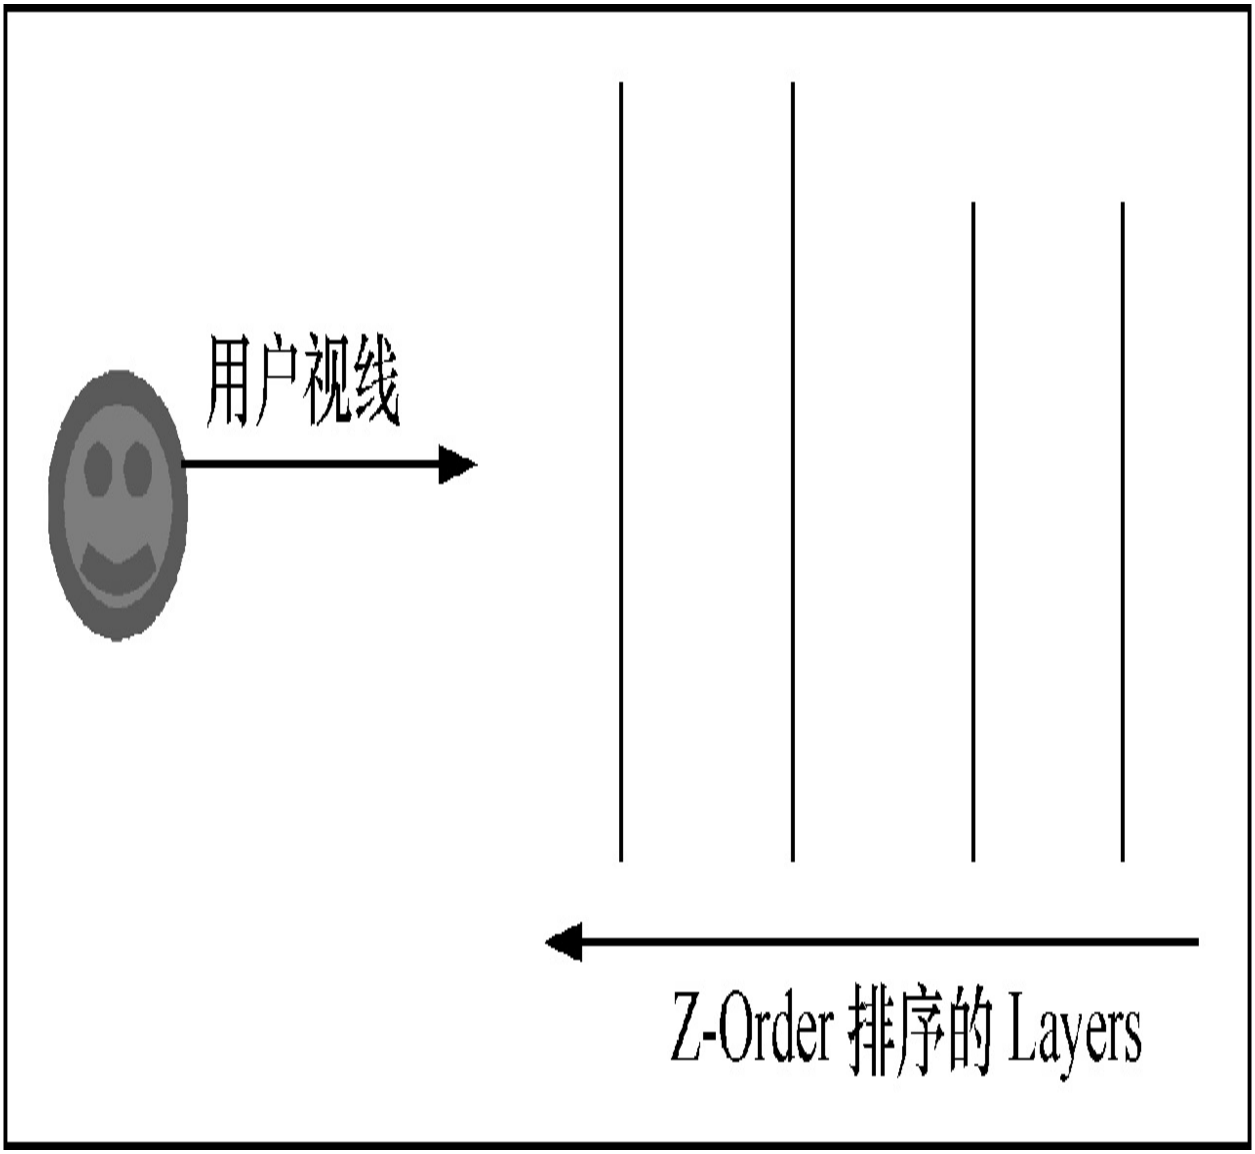

▲图9-41　后面的Layer有可能被遮挡而不可见

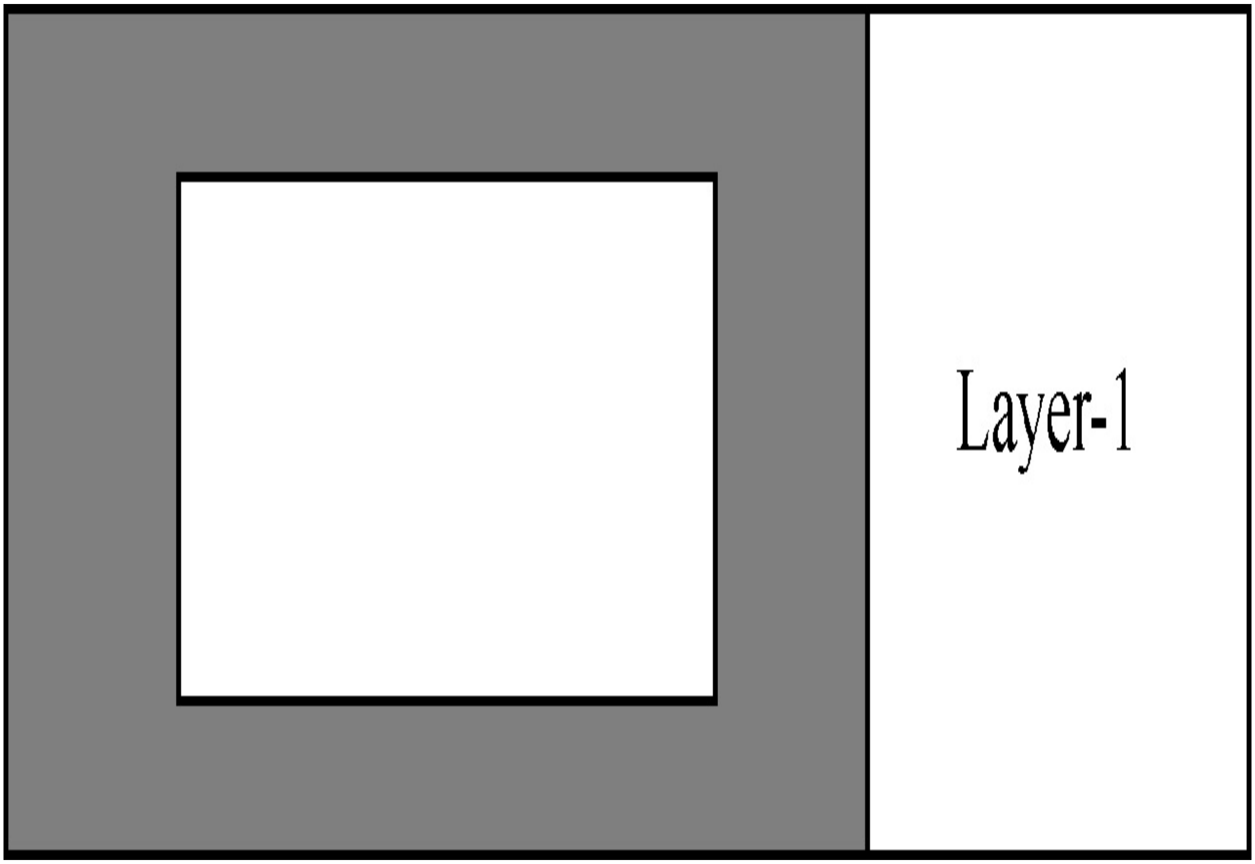

▲图9-42　Z-Order最大的Layer可见区域示意图

如图9-42所示，最外围边框是这个“图层”的尺寸大小，中间挖空区域则是完全透明的，因而需要被剔除。半透明区域比较特殊，它既属于上一个“图层”的可见区域，又不被列为遮盖区域。

- 对于Z-Order不是最大的Layer，它首先要计算自身所占区域扣除aboveCoveredLayers（即被Z-Order比它大的Layers遮盖的部分）后所剩的空间，然后才能像上一步一样再去掉完全透明的区域，这样得到的结果就是它最终的可见区域，如图9-43所示。

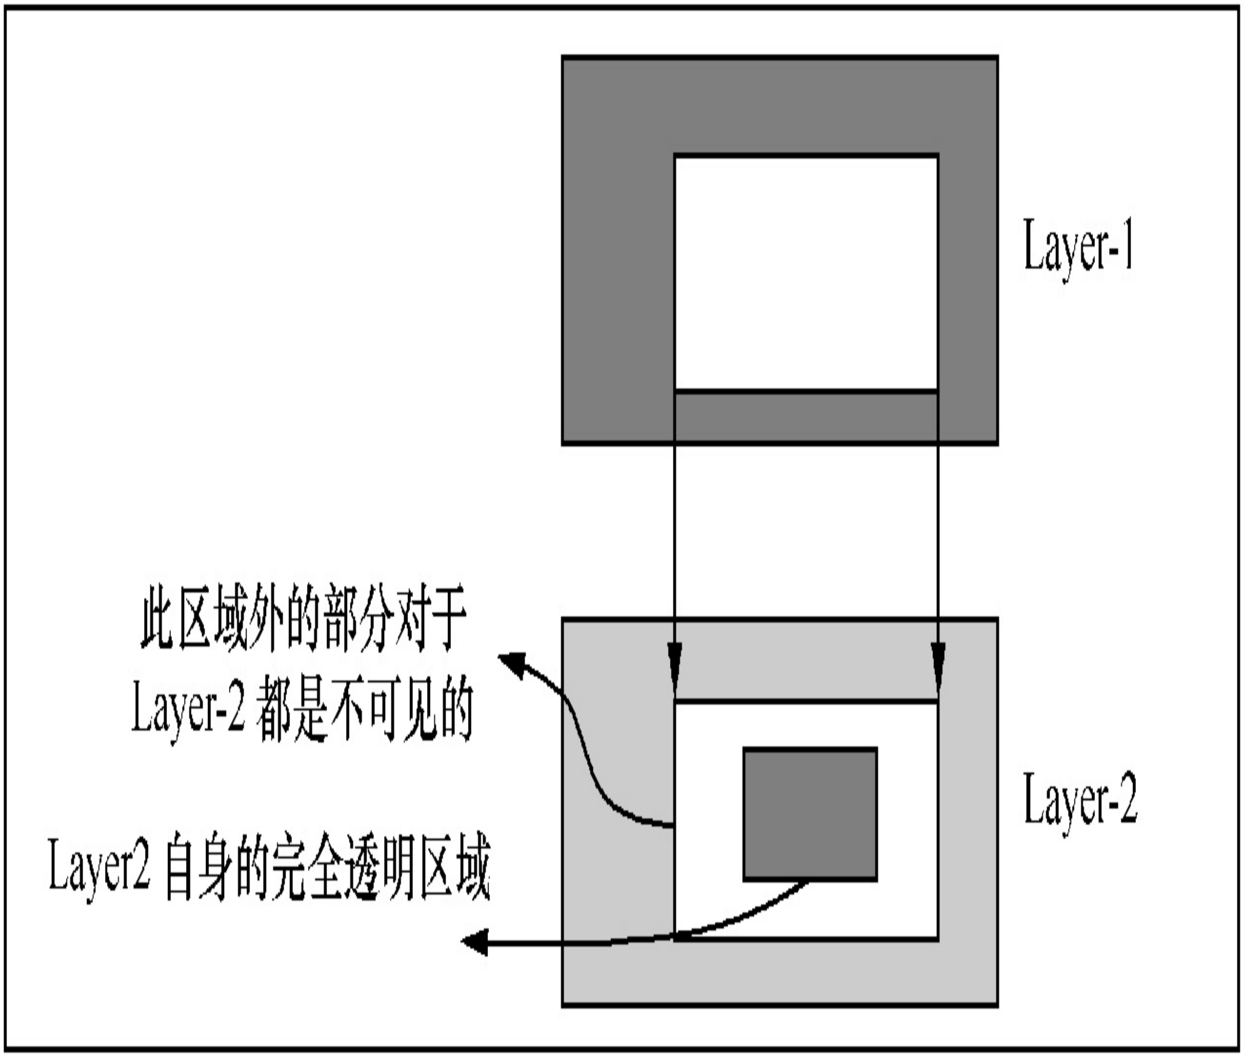

▲图9-43　其他Layer的可见区域计算

现在我们可以进入源码分析了：

```
void SurfaceFlinger::computeVisibleRegions(const LayerVector& cur
{…
    Region aboveOpaqueLayers;//对于当前Layer来说，是在它“上面”的不透明
    Region aboveCoveredLayers;/*对于当前Layer来说，是在它“上面”的遮盖区
    Region dirty;

    outDirtyRegion.clear();//清零
    size_t i = currentLayers.size();
    while (i--) {//逐步处理各Layer，并按照Z-Order递减的顺序
        const sp<Layer>& layer = currentLayers[i];//当前处理的Layer

        const Layer::State& s(layer->drawingState());
```

```
if (s.layerStack != layerStack)/*又进行了一次检查，如果此Laye
    continue;
/*接下来的几个变量是计算的基础*/
Region opaqueRegion;//用于记录完全透明区域
Region visibleRegion;//可见区域，前面已经讲解过了
Region coveredRegion;//被覆盖的区域，前面已经讲解过了
Region transparentRegion;//完全透明区域

if (CC_LIKELY(layer->isVisible())) {//判断Layer的Visible属
   const bool translucent = !layer->isOpaque();/*不是Opaqu
                                          translucent
   Rect bounds(s.transform.transform(layer->computeBounds
   visibleRegion.set(bounds);//bounds就是初始的可见区域
   if (!visibleRegion.isEmpty()) {
       //计算transparentRegion，代码略…
       //接着计算opaqueRegion:
       const int32_t layerOrientation = s.transform.getOr
       if (s.alpha==255 && !translucent &&
    ((layerOrientation & Transform::ROT_INVALID) == false
          opaqueRegion = visibleRegion;//在满足上述几个条件时
      }
   }
}
coveredRegion = aboveCoveredLayers.intersect(visibleRegio
aboveCoveredLayers.orSelf(visibleRegion);//为下一个Layer计
visibleRegion.subtractSelf(aboveOpaqueLayers);/*前面我们说
                                          需要考虑被其上面
/*现在可见区域已经得出来了，可以在此基础上计算“脏”区域了。换句话说，
“在可见区域范围内的那些需要被重新绘制的内容”*/
if (layer->contentDirty) {//是否要重新绘制所有区域
    dirty = visibleRegion;//是的话“脏”区域自然就等于可见区域了
    dirty.orSelf(layer->visibleRegion);//以及老的visibleRe
    layer->contentDirty = false;
} else {//不需要重新绘制所有区域的情况，见后面的注释1
    const Region newExposed = visibleRegion - coveredRegi
    const Region oldVisibleRegion = layer->visibleRegion;
    const Region oldCoveredRegion = layer->coveredRegion;
    const Region oldExposed = oldVisibleRegion - oldCover
    dirty = (visibleRegion&oldCoveredRegion) | (newExpose
}
dirty.subtractSelf(aboveOpaqueLayers);
outDirtyRegion.orSelf(dirty);//将此Layer的“脏区域”累加到全局
aboveOpaqueLayers.orSelf(opaqueRegion);//更新aboveOpaqueLa

/*将这些计算结果存储到layer中，供后续判断使用：*/
layer->setVisibleRegion(visibleRegion);
layer->setCoveredRegion(coveredRegion);
layer->setVisibleNonTransparentRegion(visibleRegion.subtr
```

```
    }
    outOpaqueRegion = aboveOpaqueLayers;//最终的不透明区域就是aboveOp
}
```

注释1：

在不需要全部重绘的情况下，应考虑如下因素：

（1）这一次被“暴露”出来的区域（newExposed）；

（2）上一次的可见区域（oldVisibleRegion）；

（3）上一次被覆盖的区域（oldCoveredRegion）；

（4）上一次被“暴露”出来的区域（oldExposed）。

相信不少读者会有这样的疑问，本次的dirty区域为什么要考虑“上一次”的结果呢？举个例子：假设在上一次的计算过程中，“脏”区域原本有oldDirty那么大，但是受限于可见区域，有一部分oldDirty内容（暂且称之为missedDirty）很可能并没有真正“显示”到屏幕上；而到了本次计算时，如果missedDirty区域没有任何变化，就意味着它不再是Dirty的了——此时如果我们只考虑本次的结果，那么这部分区域肯定是不会被“绘制”出来的。

这样我们就分析完rebuildLayerStacks的处理过程了，这些计算结果将影响后续SurfaceFlinger的合成操作。

9.7.7　为“Composition”搭建环境——setUpHWComposer

“万事俱备，只欠东风”，经过前面两步的努力，“合成”操作所需的各种数据已经准备好了。接下来的setUpHWComposer就是为“Composition”搭建环境。

关于HWComposer我们在前几个小节已经接触过，要特别注意源码工程中有两个HWComposer.h文件，分别是：

```
hardware/libhardware/include/hardware/HWComposer.h
frameworks/native/services/surfaceflinger/displayhardware/HWCompo
```

第一个HWComposer属于HAL模块的定义；后面一个则是

SurfaceFlinger管理HWComposer模块而设计的。在SurfaceFlinger::readyToRun中，程序会调用：

```
mHwc = new HWComposer(this, *static_cast<HWComposer::EventHan
```

此时生成的HWComposer担当的是“管理者”身份，而它的构造函数中又进一步通过loadHwcModule来加载名称为“HWC_HARDWARE_MODULE_ID”的HWComposer模块，如图9-44所示。

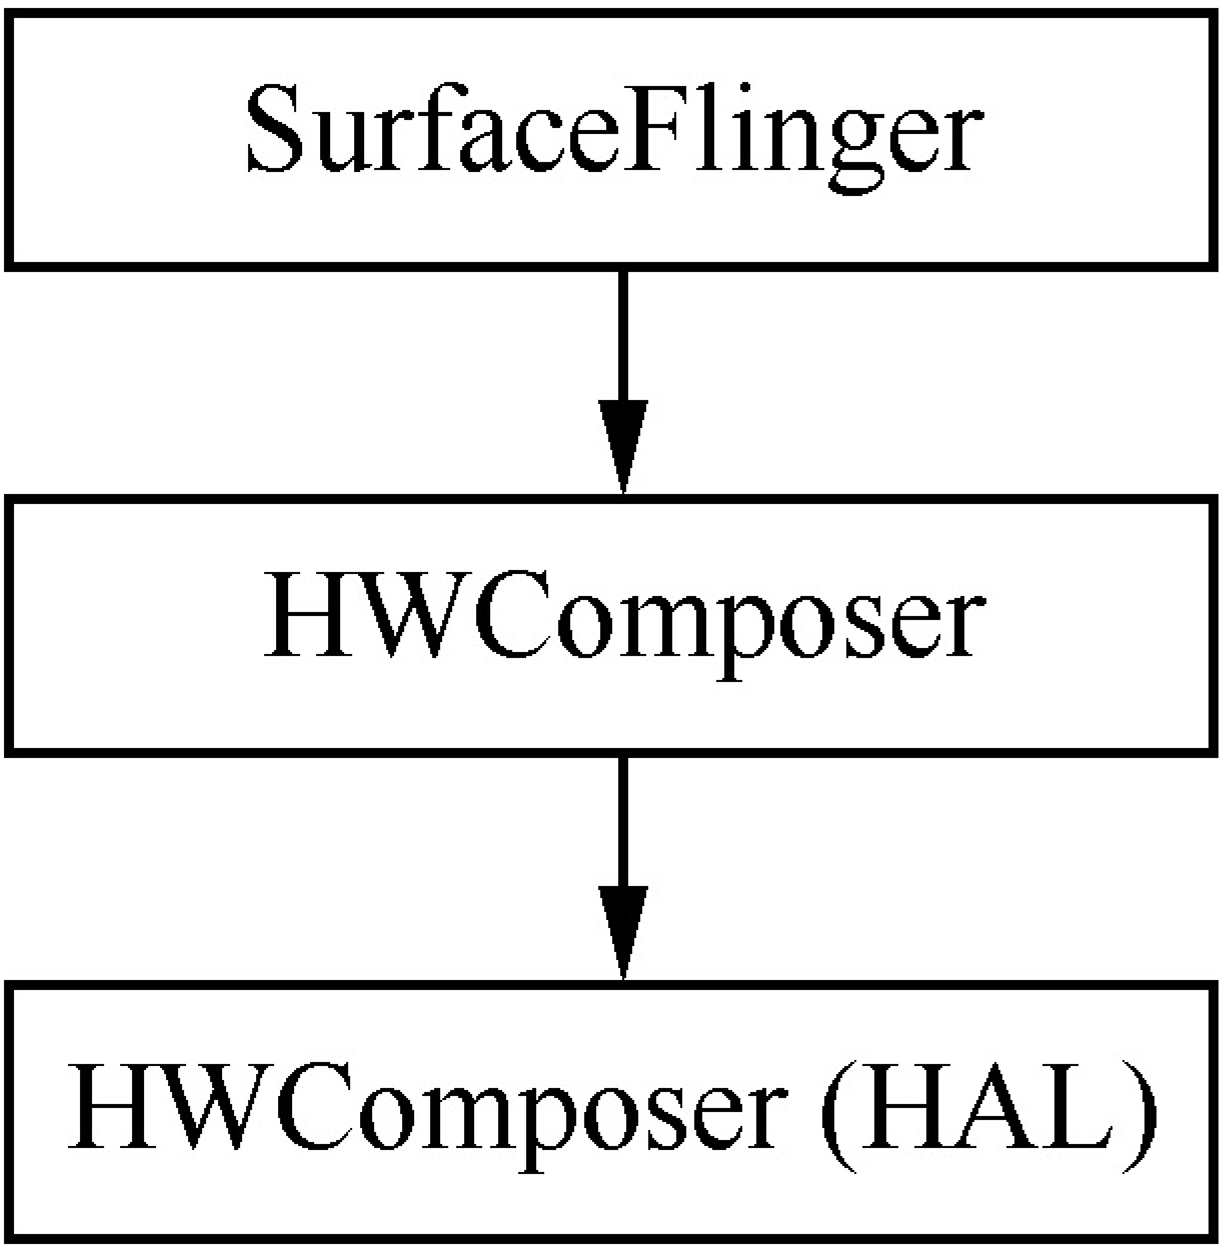

▲图9-44 两个HWComposer对象

先来了解下HAL层的HWComposer提供的接口，如表9-8所示。

表9-8　HWComposer的HAL接口

Interface	Description
prepare	在每帧图像合成前，都会被调用。它用于判断HWC模块在合成操作中所能完成的功能。具体而言，prepare的第三个函数参数：hwc_display_contents_1_t** displays中有个hwc_layer_1_t hwLayers[0]成员变量，而hwc_layer_1_t中的compositionType则是HWC对prepare的回应，详细的CompositionType类型描述请参见后面表格
set	set接口用于代替早期版本中的eglSwapBuffers，因而从功能上看它们是基本相同的。通过前一个prepare，现在SurfaceFlinger和HWC模块已经达成了共识——即哪些Layer是可以由HWC来处理的（也就是源码中所称的Work List），所以set函数就是将这些Layer的具体数据传送给HWC做实际的操作。要特别注意的是，set中传入的Layer list必须与prepare计算出来的结果保持一致。可以猜想到，set内部实现中一定会调用eglSwapBuffers，有兴趣的读者可以找一个具体的HWC模块实现来验证下
eventControl	用于控制display相关的events的开/关，如HWC_EVENT_VSYNC
blank	用于控制屏幕的开启和关闭
query	用于查询HWC的各种状态

registerProcs	用于向HWC注册callback函数，详情参见后续介绍

CompositionType对整个合成过程是很重要的参考值，如表9-9所示。

表9-9　参考值

CompostionType	Description
HWC_BACKGROUND	在prepare前被调用者设置的值。表明这是一个特别的“background”图层，此时只有backgroundColor是有效的
HWC_FRAMEBUFFER_TARGET	也是在prepare前被调用者设置的值。表明此图层是OpenGL ES合成时的目标“framebuffer surface”。只在HWC_DEVICE_API_VERSION_1_1以后的版本有效
HWC_FRAMEBUFFER	在prepare前被调用者设置的值，且要求HWC_GEOMETRY_CHANGED也应该置位。表明Layer将通过OpenGL ES来绘制到framebuffer中
HWC_OVERLAY	在prepare的执行过程中由HWC模块来设置的值。表示该图层将由HWC处理，而不是像上面的

	HWC_FRAMEBUFFER那样由OpenGL ES来绘制

通过表9-9的解释，大家应该可以了解到如下信息：合成过程既可以由HWC模块来完成，也可以通过OpenGL ES来处理。具体采用哪种方式是由prepare()的结果，即CompositionType来决定的。

使用者可以向HWC模块注册callback函数来接收相关事件，包括：

```
typedef struct hwc_procs {
void (*invalidate)(const struct hwc_procs* procs);/*触发屏幕刷新*/
void (*vsync)(const struct hwc_procs* procs, int disp, int64_t ti
                   前面表格中的eventControl接口将HWC_EVENT_VSYNC事件打
                   VSync信号的话就会回调此函数*/
void (*hotplug)(const struct hwc_procs* procs, int disp, int conn
                          被connected或者disconnected时会回调此函数。
                          display必须一直是connected的，所以不适用此函
…
```

了解了以上这些知识，现在我们可以来分析setUpHWComposer的源码实现了。

```
void SurfaceFlinger::setUpHWComposer() {
    HWComposer& hwc(getHwComposer());
    if (hwc.initCheck() == NO_ERROR) {
        if (CC_UNLIKELY(mHwWorkListDirty)) {//当mHwWorkListDirty为
            mHwWorkListDirty = false;
            for (size_t dpy=0 ; dpy<mDisplays.size() ; dpy++) {//
                sp<const DisplayDevice> hw(mDisplays[dpy]);
                const int32_t id = hw->getHwcDisplayId();
                if (id >= 0) {
                    const Vector< sp<Layer>>& currentLayers(hw->g
                    const size_t count = currentLayers.size();//L
                    if (hwc.createWorkList(id, count) == NO_ERROR
                         …//详细处理省略
                    }
                }
            }
        }

        // set the per-frame data
        for (size_t dpy=0 ; dpy<mDisplays.size() ; dpy++) {
            sp<const DisplayDevice> hw(mDisplays[dpy]);
```

```
            const int32_t id = hw->getHwcDisplayId();
            if (id >= 0) {
                const Vector< sp<Layer>>& currentLayers(hw->getVi
                /*注意，是所有可见Layers，即前面小节的计算结果*/
                const size_t count = currentLayers.size();
                HWComposer::LayerListIterator cur = hwc.begin(id)
                const HWComposer::LayerListIterator end = hwc.end
                for (size_t i=0 ; cur!=end && i<count ; ++i, ++cu
                    const sp<Layer>& layer(currentLayers[i]);
                    layer->setPerFrameData(hw, *cur);//Step2. 注意
                }
            }
        }
        status_t err = hwc.prepare();/*Step3. 调用HWC的prepare*/
        ALOGE_IF(err, "HWComposer::prepare failed (%s)", strerror
    }
}
```

刚接触这个函数，相信不少读者会觉得无从下手。鉴于此，我们希望能以最简洁的方式把setUpHWComposer的“骨干”体现出来。

用一句话来概括，setUpHWComposer用于把需要显示的那些Layer的数据准备好，然后“报告”给HWC模块来决定由谁（OpenGL ES或者HWC自己）进行最终的“合成”工作。

细化来说，实际上它只完成了3件事（也就是代码中颜色加深的部分）。

Step1@SurfaceFlinger::setUpHWComposer，构造Work List。这个词的字面意思是“工作事项”，它是SurfaceFlinger写给HWC “报告”的标准格式。完成WorkList构造工作的是createWorkList，这个函数会从全局变量mDisplayData中取出与Display对应的DisplayData，然后给其中各field进行必要的赋值（其中最重要的就是给DisplayData::list申请空间）。

Step2@SurfaceFlinger::setUpHWComposer。好了，现在我们已经构造出了WorkList，接下来还要填充各Layer的数据。这项工作是由每个Layer单独完成的，调用的接口是setPerFrameData。关键源码如下：

```
void Layer::setPerFrameData(const sp<const DisplayDevice>& hw,HWC
    const Transform& tr = hw->getTransform();
    Region visible = tr.transform(visibleRegion.intersect(hw->get
```

```
    layer.setVisibleRegionScreen(visible);
    layer.setBuffer(mActiveBuffer);//允许buffer为NULL
}
```

根据前几个小节对显示数据的分析，我们知道各“Producer”生产出来的数据是存储在GraphicBuffer中的，而mActiveBuffer则代表的是当前“活跃”的Buffer——它将被设置到layer变量（要特别注意，这个layer的数据类型是HWComposer::HWCLayerInterface，而不是Layer）中作为本次合成的数据。值得一提的是，mActiveBuffer是有可能为NULL的，表明生产者还未生产东西，或者内存不足。

Step3@SurfaceFlinger::setUpHWComposer。一切准备就绪，现在可以“报告”HWC了。不过不要忘记有两个HWComposer，所以这里调用的prepare其实是displayhardware目录下的类实现：

```
/*frameworks/native/services/surfaceflinger/displayhardware/HWCom
status_t HWComposer::prepare() {
    for (size_t i=0 ; i<mNumDisplays ; i++) {
        DisplayData& disp(mDisplayData[i]);
        …
        mLists[i] = disp.list;
        …
    }
    int err = mHwc->prepare(mHwc, mNumDisplays, mLists);//真正调用H
    …
    return (status_t)err;
}
```

上面代码段中的mHwc是与HWC的HAL模块相对应的。函数prepare会对DisplayData::list做进一步的赋值操作，然后集中所有Display中的list（即mLists）一并传给HWC::prepare。注意：mLists是一个数组指针，或者说是二级指针，这是HWC能正确执行prepare的关键。

这样HWC就在WorkList的基础上判断出有哪些Layer是可以由它来完成的了。

9.7.8 doDebugFlashRegions

当mDebugRegion变量为true时，系统才会执行doDebugFlashRegions。而mDebugRegion本身则是由系统属性debug.sf.showupdates来决定的，默认值为false，所以我们直接略

过。

9.7.9　doComposition

还记得我们在setUpHWComposer小节中对HWC提供的各HAL接口的描述吗？前面的setUpHWComposer只是将显示数据“报告”（prepare）给了HWC，决定了由谁来执行“合成”操作，而真正的工作还并未开始——显然，这是doComposition所要实现的功能。

对于合成过程有两个核心点：

- 如何合成;
- 如何显示到屏幕上。

前面已经讲过，“合成”既可以由OpenGL ES完成，也可以通过HWC模块来处理，区别的关键就在于CompositionType；而将UI数据显示到屏幕上的关键则是eglSwapBuffers，如图9-45所示。

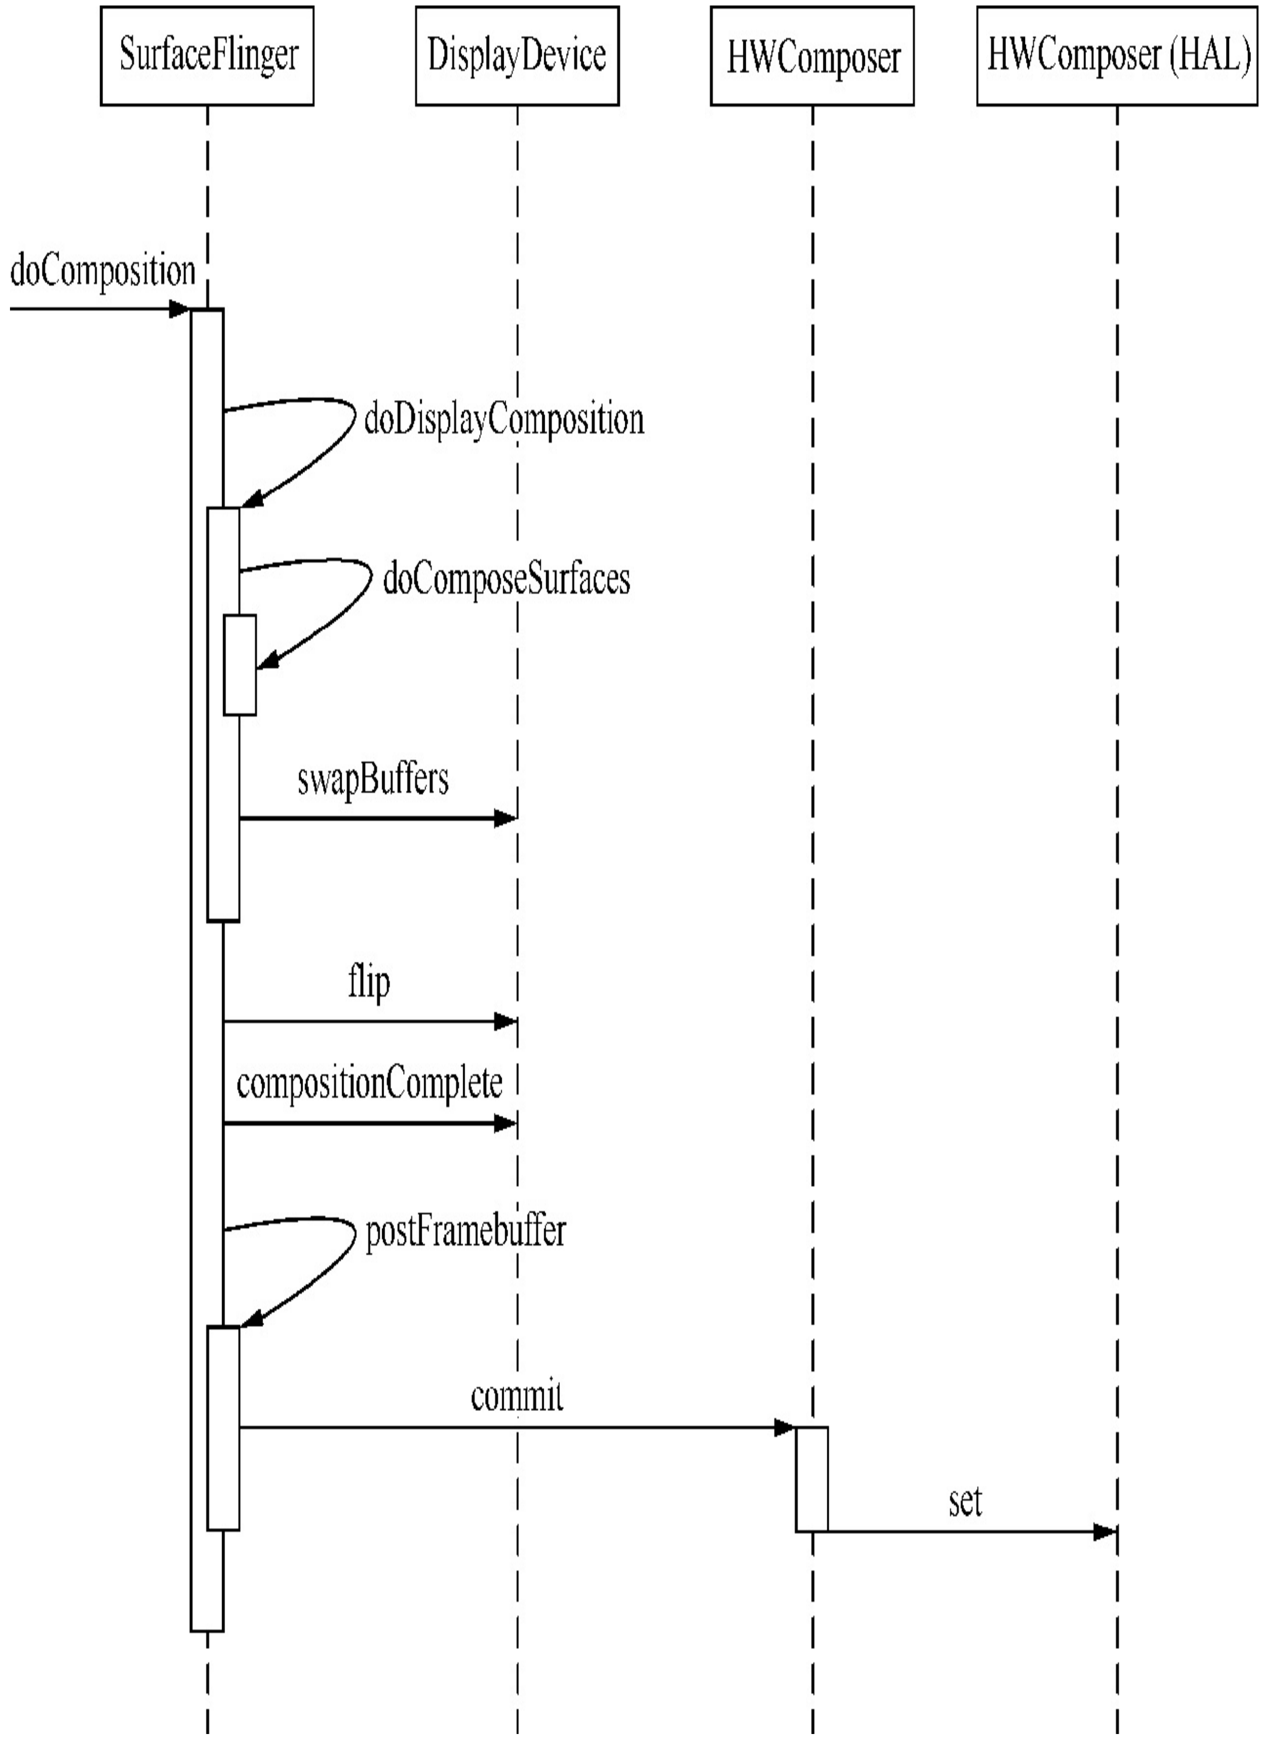
SurfaceFlinger
DisplayDevice
HWComposer
HWComposer (HAL)
doComposition
doDisplayComposition
doComposeSurfaces
swapBuffers
flip
compositionComplete
postFramebuffer
commit
set

▲图9-45 doCompostion的调用流程图

接下来我们根据流程图来展开源码分析：

```
void SurfaceFlinger::doComposition() {
    ATRACE_CALL();
    const bool repaintEverything = android_atomic_and(0, &mRepain
    //是否需要"重绘"所有数据
    for (size_t dpy=0 ; dpy<mDisplays.size() ; dpy++) {//逐个处理D
        const sp<DisplayDevice>& hw(mDisplays[dpy]);
        if (hw->canDraw()) {
            const Region dirtyRegion(hw->getDirtyRegion(repaintEv
            doDisplayComposition(hw, dirtyRegion);//有可能会调用egl
            hw->dirtyRegion.clear();
            hw->flip(hw->swapRegion);
            hw->swapRegion.clear();
        }
        hw->compositionComplete();//通知HWC合成已经完成
    }
    postFramebuffer();//HWC的set接口就是在这里调用的
}
```

变量mRepaintEverything用于指示是否要“重绘”所有内容。一旦这个变量为true的话，那么dirtyRegion直接就等于由DisplayDevice中的mDisplayWidth和mDisplayHeight组成的Rect；否则由DisplayDevice::dirtyRegion转换成屏幕坐标而来。

对于每个DisplayDevice而言，它们需要单独调用doDisplayComposition——这个函数有可能通过eglSwapBuffers来交换前后台Buffer。如下所示：

```
void SurfaceFlinger::doDisplayComposition(const sp<const DisplayD
Region& inDirtyRegion)
{
    Region dirtyRegion(inDirtyRegion);
    hw->swapRegion.orSelf(dirtyRegion);
    uint32_t flags = hw->getFlags();
    /*先对dirtyRegion进行"微调"*/
    if (flags & DisplayDevice::SWAP_RECTANGLE) {
        dirtyRegion.set(hw->swapRegion.bounds());
    } else {
        if (flags & DisplayDevice::PARTIAL_UPDATES) {
            dirtyRegion.set(hw->swapRegion.bounds());
```

```
        } else {
            dirtyRegion.set(hw->bounds());
            hw->swapRegion = dirtyRegion;
        }
    }
    doComposeSurfaces(hw, dirtyRegion);//合成数据
    …
    hw->swapBuffers(getHwComposer());//交换前后台(如果需要的话)
}
```

虽然函数入参inDirtyRegion已经指明了“脏”区域，但它并不是直接可用的，还需要根据条件进行微调。

- DisplayDevice::SWAP_RECTANGLE

此时只要求渲染“脏”区域，或者说系统在软件层面上支持部分区域更新，但更新区域必须是长方形的。由于这个限制，dirtyRegion应该是覆盖所有“脏”区域的最小矩形。

- DisplayDevice::PARTIAL_UPDATES

系统支持硬件层面部分区域更新，同样也要求是矩形区域。

- 其他

除了上面两种情况外，我们需要“重绘”整个Display区域，即hw.bounds()。

确认完最终的dirtyRegion后，现在可以调用doComposeSurfaces了。从名称中可以看出，这个函数用于“Compose” Surface。相信读者会有疑问，这里的Surface指什么呢？

```
void SurfaceFlinger::doComposeSurfaces(const sp<const DisplayDevi
Region& dirty)
{
    const int32_t id = hw->getHwcDisplayId();
    HWComposer& hwc(getHwComposer());
    HWComposer::LayerListIterator cur = hwc.begin(id);
    const HWComposer::LayerListIterator end = hwc.end(id);

    const bool hasGlesComposition = hwc.hasGlesComposition(id) ||
```

```
    if (hasGlesComposition) {
        if (!DisplayDevice::makeCurrent(mEGLDisplay, hw, mEGLCont
           ALOGW("DisplayDevice::makeCurrent failed. Aborting sur
                  hw->getDisplayName().string());
            return;
        }
        glMatrixMode(GL_MODELVIEW);//指定哪一个矩阵是当前矩阵
        glLoadIdentity();//单位矩阵
        const bool hasHwcComposition = hwc.hasHwcComposition(id);
        if (hasHwcComposition) {
            glClearColor(0, 0, 0, 0);
            glClear(GL_COLOR_BUFFER_BIT);
        } else {
            …
        }
        …
    }
    const Vector< sp<Layer>>& layers(hw->getVisibleLayersSortedBy
    const size_t count = layers.size();
    const Transform& tr = hw->getTransform();
    if (cur != end) {/*使用HWC的情况*/
        …/*代码后续分析*/
    } else {/*不使用HWC的情况*/
        …//代码省略
    }
    …
}
```

先来看两个变量：

1．hasGlesComposition

这个变量在两种情况下会是true。

- 在prepare的处理过程中，如果有layer的compositionType是HWC_FRAMEBUFFER，那么DisplayData:: hasFbComp会被置为true——通常情况下，HWComposer:: hasGlesComposition就是由它决定的。
- cur==end，此时说明需要由OpenGL ES来处理合成。

2．hasHwcComposition

需要特别注意的是，这个变量和hasGlesComposition并不是互斥

的，它们有可能同时为true——这种情况说明既有需要OpenGL ES处理的layer，也有需要HWC来执行合成的layer。

了解这两个变量，对理清doComposeSurfaces的函数逻辑有一定帮助。

如果hasGlesComposition条件成立的话，那么程序首先通过makeCurrent来设置当前的渲染环境，然后调用glMatrixMode(GL_MODELVIEW)来设置当前矩阵。顺便说一下，glMatrixMode有3种可选参数，具体包括如下。

GL_MODELVIEW：将接下来的矩阵操作应用到模型视景矩阵中。

GL_PROJECTION：将接下来的矩阵操作应用到投影矩阵中。

GL_TEXTURE：将接下来的矩阵操作应用到纹理矩阵中。

它通常与glLoadIdentity一起使用，后者会把当前矩阵设置为单位矩阵。

紧接着如果hasHwcComposition为true的话，那么程序会使用glClear来将窗口清除为glClearColor所指定的color，即（0,0,0,0）。

做完这些工作后，程序就真正进入“图层”的处理了。这里又分为两种情况：

1．cur== end

此时就不是由HWC来主导了，核心实现是通过layer->draw来完成的，下面有详细讲解。

2．cur!= end

说明将使用HWC Composer。这部分代码如下：

```
for (size_t i=0 ; i<count && cur!=end ; ++i, ++cur) {
      const sp<Layer>& layer(layers[i]);
      const Region clip(dirty.intersect(tr.transform(layer-
```

```
            if (!clip.isEmpty()) {
                switch (cur->getCompositionType()) {
                    case HWC_OVERLAY: {
                        if ((cur->getHints() & HWC_HINT_CLEAR_FB)
                                 && layer->isOpaque()&& hasGlesCo
                            layer->clearWithOpenGL(hw, clip);
                        }
                        break;
                    }
                    case HWC_FRAMEBUFFER: {
                        layer->draw(hw, clip);//由OpenGL ES来处理
                        break;
                    }
                    …
                }
            }
            layer->setAcquireFence(hw, *cur);
        }
```

细节部分我们不再赘述，读者可以自行阅读。当CompositionType为HWC_FRAMEBUFFER时，说明此layer需要由OpenGL ES来处理，具体而言就是调用layer->draw，然后draw又直接调用了onDraw：

```
void Layer::onDraw(const sp<const DisplayDevice>& hw, const Regio
{…
    if (CC_UNLIKELY(mActiveBuffer == 0)) {
         /*如果texture还没有生成，换句话说，此Layer未绘制过。这是有可能发
         没有办法知道客户程序什么时候才会进行第一次绘制。当发生这种情况时，如
         东西的话，就将屏幕“涂黑”，否则跳过*/
         …//代码略
    }
    status_t err = mSurfaceFlingerConsumer->bindTextureImage();
    …//OpenGL ES环境的准备工作，省略
    drawWithOpenGL(hw, clip);
    …
}
```

变量mActiveBuffer在前面几个小节的处理中已经被设置成最新的缓冲区了。但它有可能是空的，如应用程序还没有开始做绘制工作，在此之前都可能发生这种情况。此时程序将进一步找出所有在此layer之下的可见区域，再由此计算不会被遮盖的区域：

```
Region holes(clip.subtract(under));
```

除holes之外的所有区域，都会被“涂黑”，这是由

clearWithOpenGL(holes, 0, 0, 0, 1)完成的。紧接着通过SurfaceFlingerConsumer::bindTextureImage来把当前缓冲区数据绑定到OpenGL纹理中。

接下来根据当前情况调用opengl的各API接口进行必要配置，为drawWithOpenGL做最后准备工作：

```
void Layer::drawWithOpenGL(const sp<const DisplayDevice>& hw, con
    const uint32_t fbHeight = hw->getHeight();//Display的高度
    const State& s(drawingState());//即mDrawingState
    /*Part1: 判断是否需要BLEND? */
    GLenum src = mPremultipliedAlpha ? GL_ONE : GL_SRC_ALPHA;
    if (CC_UNLIKELY(s.alpha < 0xFF)) {//非完全不透明
        const GLfloat alpha = s.alpha * (1.0f/255.0f);;//归一化
        if (mPremultipliedAlpha) {//预乘alpha打开
            glColor4f(alpha, alpha, alpha, alpha);//两个函数的RGBA者
        } else {
            glColor4f(1, 1, 1, alpha);
        }
        glEnable(GL_BLEND);//需要混合
        glBlendFunc(src, GL_ONE_MINUS_SRC_ALPHA);//制定混合算法
        glTexEnvx(GL_TEXTURE_ENV, GL_TEXTURE_ENV_MODE, GL_MODULAT
    } else {//完全不透明，alpha为1
        glColor4f(1, 1, 1, 1);
        glTexEnvx(GL_TEXTURE_ENV, GL_TEXTURE_ENV_MODE, GL_REPLACE
        if (!isOpaque()) {//不是opaque，也需要blend
            glEnable(GL_BLEND);
            glBlendFunc(src, GL_ONE_MINUS_SRC_ALPHA);//同前面s.alp
        } else {
            glDisable(GL_BLEND);//不需要blend
        }
    }

    /*Part2: 下面开始执行具体操作*/
    …
    struct TexCoords {    /*顶点结构体*/
        GLfloat u;
        GLfloat v;
    };

    const Rect win(computeBounds());//边框
    GLfloat left = GLfloat(win.left) / GLfloat(s.active.w);//左边纟
    GLfloat top = GLfloat(win.top) / GLfloat(s.active.h);//上边缘
    GLfloat right = GLfloat(win.right) / GLfloat(s.active.w);//右ì
    GLfloat bottom = GLfloat(win.bottom) / GLfloat(s.active.h);//
```

```
    TexCoords texCoords[4];//定义4个顶点
    texCoords[0].u = left;/*texCoords[4]，分别用来表示下面的几个顶点*/
    texCoords[0].v = top;/*win框的左上、左下、右下和右上的4个顶点*/
    texCoords[1].u = left;
    texCoords[1].v = bottom;
    texCoords[2].u = right;
    texCoords[2].v = bottom;
    texCoords[3].u = right;
    texCoords[3].v = top;
    for (int i = 0; i < 4; i++) {
        texCoords[i].v = 1.0f - texCoords[i].v;
    }

    glEnableClientState(GL_TEXTURE_COORD_ARRAY);//接下来要处理纹理坐
    glTexCoordPointer(2, GL_FLOAT, 0, texCoords);//设置纹理坐标数组
    glVertexPointer(2, GL_FLOAT, 0, mesh.getVertices());//设置顶点
    glDrawArrays(GL_TRIANGLE_FAN, 0, mesh.getVertexCount());/*根据
                                                               pri

    glDisableClientState(GL_TEXTURE_COORD_ARRAY);
    glDisable(GL_BLEND);//关闭BLEND
}
```

整个函数逻辑分为两部分：首先判断是否需要BLEND，然后再执行具体的操作。

变量mPremultipliedAlpha表示“预乘alpha通道”，它是RGBA的另一种表达方式。比如传统的RGBA是（r,g,b,a），而premultiplied alpha就是（ra,ga,ba,a）。在某些场景下采用后一种方式能达到更好的效果，大家可以自行查阅相关资料以了解详情。

因而当mPremultipliedAlpha为true时，设置颜色：

```
glColor4f(alpha, alpha, alpha, alpha);
```

否则就是：

```
glColor4f(1, 1, 1, alpha);
```

在判断是否需要BLEND时有如下几种情况。

- 当前不是完全不透明的

毋庸置疑，这种情况需要开启BLEND。

- 当前是完全不透明的

如果isOpaque()返回值为false，那么还是需要开启BLEND功能；否则Disable BLEND。

开启BLEND在Opengl ES中对应的API是glEnable(GLenum cap)，参数为GL_BLEND。BLEND的目的就是通过“源色”和“目标色”的混合计算来产生透明特效，有多种混合算法可供选择，由glBlendFunc来配置：

```
glBlendFunc(GLenum sfactor, GLenum dfactor);
```

第一个参数是源因子，后一个则是目标因子。

可选值如表9-10所示。

表9-10　　glBlendFunc可选因子

VALUE	Description
GL_ZERO	使用0.0作为混合因子
GL_ONE	使用1.0作为混合因子
GL_SRC_COLOR	根据源颜色的各分量计算出混合因子
GL_ONE_MINUS_SRC_COLOR	根据（1-源颜色各分量）计算出混合因子
	根据源颜色的alpha计算出混合

GL_SRC_ALPHA	因子
GL_ONE_MINUS_SRC_ALPHA	根据（1.0-源颜色alpha）计算出混合因子
GL_DST_ALPHA	根据目标颜色的alpha计算出混合因子
GL_ONE_MINUS_DST_ALPHA	根据（1.0-目标颜色alpha）计算出混合因子
GL_DST_COLOR	根据目标颜色的各分量计算出混合因子
GL_ONE_MINUS_DST_COLOR	根据（1-目标颜色各分量）计算出混合因子

每种情况下混合因子的具体算法以及blend的计算公式，可以参考官方文档描述。这里我们只要明白它的使用方法即可。

完成BLEND功能的判断后，接下来就可以执行具体操作了。

首先计算纹理区域的各坐标点，结果值以texCoords[4]数组来记录。这样做的目的是保证我们能在正确的区域中绘制图形。一切准备就绪，最后就可以调用OpenGL ES的各API接口进行绘制了。

其中glEnableClientState(GL_TEXTURE_COORD_ARRAY)说明要处理的是纹理坐标数组；glVertexPointer(2, GL_FLOAT, 0, mVertices)指明是二维坐标，float数据类型，紧凑方式排列，描述顶点数组的是mVertices（这个数组值在validateVisibility中计算，个数为4）；glTexCoordPointer(2, GL_FLOAT, 0, texCoords)也表示二维坐标系，

float数据类型，紧凑排列，纹理的顶点数组由前面计算得到的texCoords表示。

最后，调用glDrawArrays(GL_TRIANGLE_FAN, 0, mNumVertices)来绘制三角形。OpenGL ES取消了对QUAD的支持，但提供了GL_TRIANGLE_FAN与GL_TRIANGLE_STRIP两种三角形绘制方式。下面大致讲解下它们的操作方式。

GL_TRIANGLE_FAN：假设有N个顶点，那么第n个三角形的顶点就是（1,n+1,n+2），总共有N-2个三角形。

GL_TRIANGLE_STRIP：假设有N个顶点，也是有N-2个三角形。

- N为奇数（odd）。那么第n个三角形的顶点是（n,n+1,n+2）。
- N为偶数（even）。那么第n个三角形的顶点就是（n+1,n,n+2）。

以这个场景为例，因为mVertices[0]- mVertices[3]分别表示左上、左下、右下、右上4个顶点（可以参见validateVisibility中的实现），那么采用这两种模式的结果如图9-46所示。

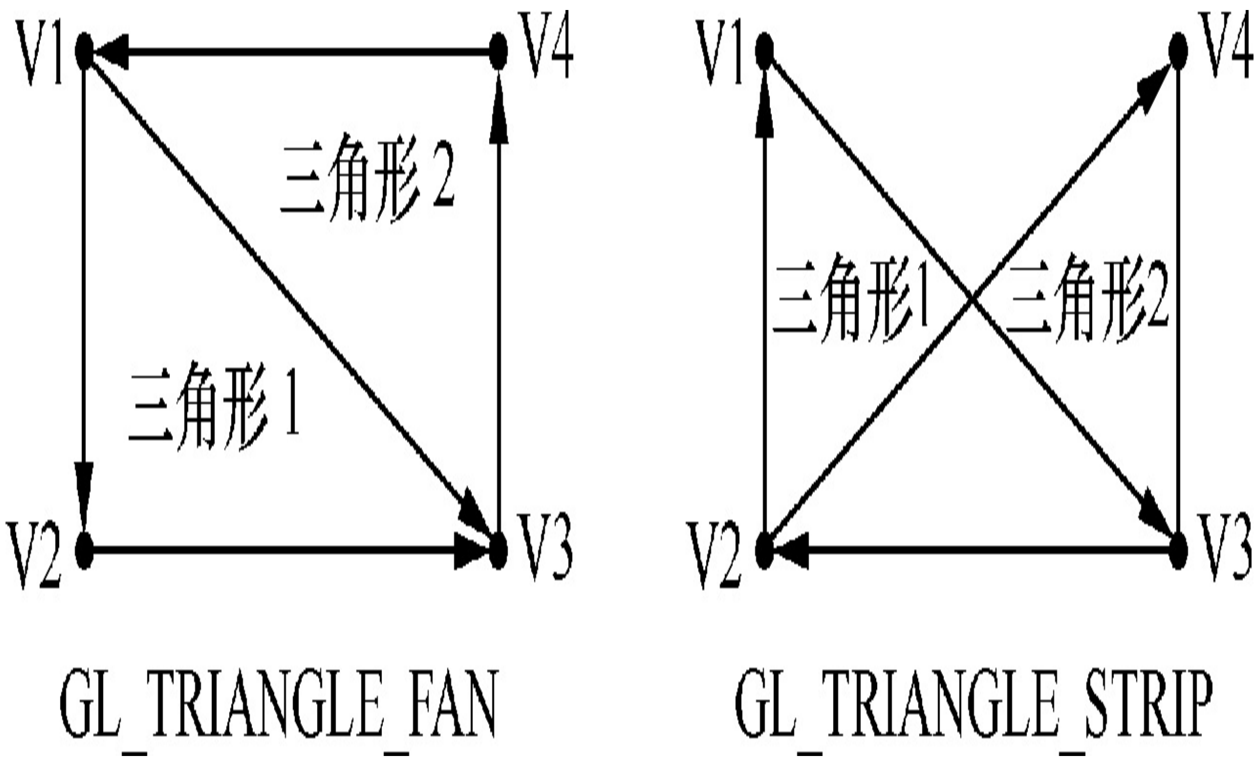

▲图9-46 三角形绘制的两种模式

这样drawWithOpenGL就成功完成当前Layer的绘制了，然后先返回doComposeSurfaces，再返回doDisplayComposition中：

```
void SurfaceFlinger::doDisplayComposition(const sp<const DisplayD
Region& inDirtyRegion)
{…
doComposeSurfaces(hw, dirtyRegion);/*返回到这里，此时已经完成了hw中相关
                                              compose工作*/
    …
    hw->swapBuffers(getHwComposer());
```

虽然相关Layer的compose已经完成，但用户此时还看不到，因为我们还需要最后一个关键操作，即swapBuffers：

```
void DisplayDevice::swapBuffers(HWComposer& hwc) const {
    if (hwc.initCheck() != NO_ERROR || (hwc.hasGlesComposition(mH
            hwc.supportsFramebufferTarget())) {
        EGLBoolean success = eglSwapBuffers(mDisplay, mSurface);
        …
    }
    …
}
```

可以看到，程序并不是在任何情况下都会调用eglSwapBuffers来交换前后台数据。需要满足如下条件之一：

- hwc.initCheck() != NO_ERROR

  也就是说，HWC模块无法正确加载使用。

- hwc.hasGlesComposition(mHwcDisplayId) &&hwc.supportsFramebufferTarget()

  有的Layer的compositionType是HWC_FRAMEBUFFER，且HWC支持Framebuffer Target。

当doDisplayComposition返回时，说明doComposition对某个DisplayDevice的处理结束，接着它会继续进入下一轮循环，直到所有DisplayDevice的处理都完成。最后，doComposition调用如下函数：

```
void SurfaceFlinger::postFramebuffer()
{…
    HWComposer& hwc(getHwComposer());
    if (hwc.initCheck() == NO_ERROR) {
        …
        hwc.commit();
    }
```

在HWComposer::commint中，将调用HWC模块的HAL接口set。这个函数我们前面已经讲解过，大家可以回头看看。

最后以图9-47来总结本小节的内容，希望能帮助读者理顺整个流程。

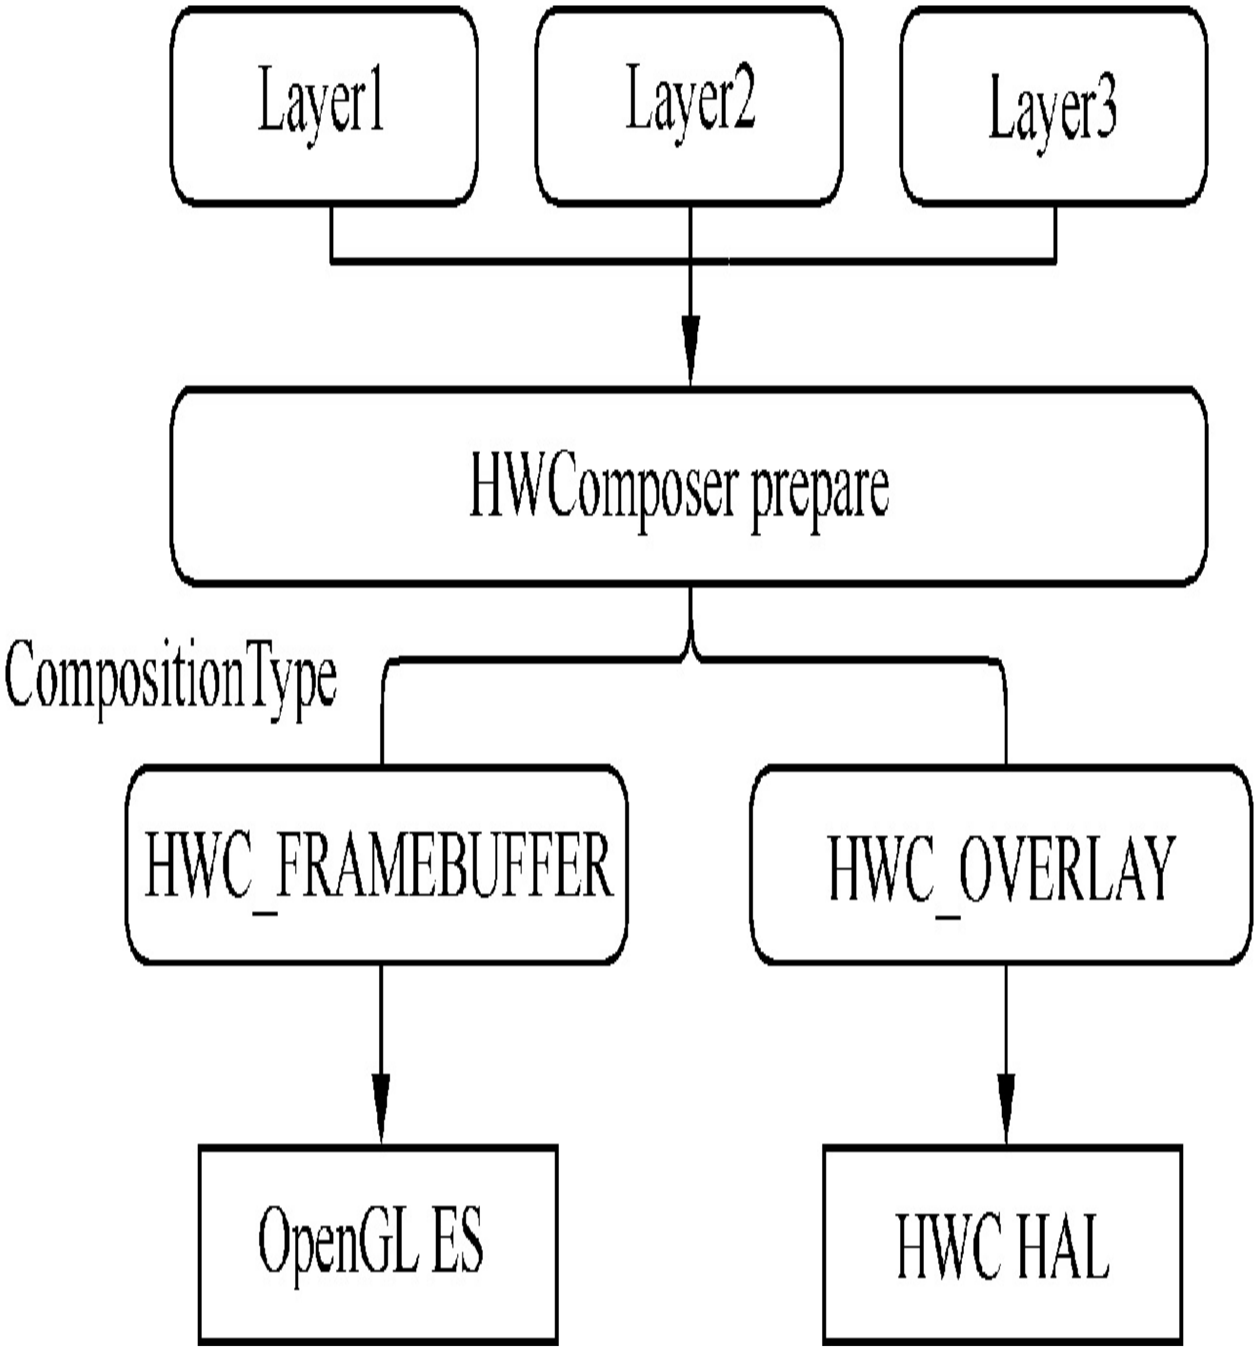

▲图9-47　Composition处理流程

第10章

GUI系统之“窗口管理员”——WMS

WindowManagerService（以下简称WMS）是做什么的？

“Window”表明它是与窗口相关的，“Manager”指出它具有管理者的身份。因而简单来说，它就是“窗口管理员”——“窗口”是一个抽象的概念，从用户的角度来讲，它是一个“界面”，如拨号面板；从SurfaceFlinger的角度来看，它是一个Layer，承载着和“界面”有关的数据和属性；从WMS的角度来看，它是一个WindowState，用于管理和“界面”有关的状态。综合来说，无论是SurfaceFlinger、WMS或者后面章节中将会分析的ViewRoot，都是在为“同一个目标”而努力——正确高效地显示UI界面，只不过大家的职责不一样。

打个比方，就像一出由N个演员参与的话剧：SurfaceFlinger是摄像机，WMS是导演，ViewRoot则是演员个体。摄像机（SurfaceFlinger）的作用是单一而规范的——它负责客观地捕获当前的画面，然后真实地呈现给观众；导演（WMS）则会考虑到话剧的舞台效果和视觉美感，如他需要根据实际情况来安排各个演员的排序站位，谁在前谁在后，都会影响到演出的“画面效果”与“剧情编排”；而各个演员的长相和表情（ViewRoot），则更多地取决于他们自身的条件与努力。正是通过这三者的“各司其职”，才能最终为观众呈现出一场美妙绝伦的“视觉盛宴”。

从计算机I/O系统的角度来分析，WMS至少要完成以下两个功能。

- 全局的窗口管理（Output）

根据计算机体系结构的分类，“窗口管理”属于“输出”部分——应用程序的显示请求在SurfaceFlinger和WMS的协助下有序地输出给物理屏幕或者其他显示设备。

- 全局的事件管理派发（Input）

与此相对应，“事件的管理派发”就可以看作WMS的“输入”功能。这同时也是WMS区别于SurfaceFlinger的一个重要因素——因为后者只做与“显示”相关的事情，而WMS则还要“兼职”对输入事件的派发。因为硬件配置的差异，不同的产品对于事件的管理需求也是不一样的。需要WMS管理的事件源包括但不限于：

- 键盘

嵌入式设备（比如手机）通常不会配备Qwerty全键盘，更多情况下只是设计了Home、Back、Menu、Vol+/-等常用的功能按键。

- 触摸屏

目前市面上的主流Android设备都配备了触摸屏。

- 鼠标

不常见，移动式设备很少支持鼠标。

- 轨迹球（Trackball）

可能不少读者对轨迹球比较陌生，它在手机发展的早期曾经存在过一段时间（如2008年上市的Google第一款手机G1），不过已经逐渐退出了历史舞台。有兴趣的读者可以自行查阅相关资料。

10.1 “窗口管理员”——WMS综述

了解了WMS“需要做什么”后，接下来可以有针对性地去分析它是“怎么做的了”。在看Android给出的答案之前，读者可以先试想一下，如果让我们来设计一个窗口管理器，该如何着手？相信经过自己的思考与探索再来研究Android中的源码，很多东西就会“一点即透”。

图10-1描述了WMS的一个设计漫想，大家可以先参考下。

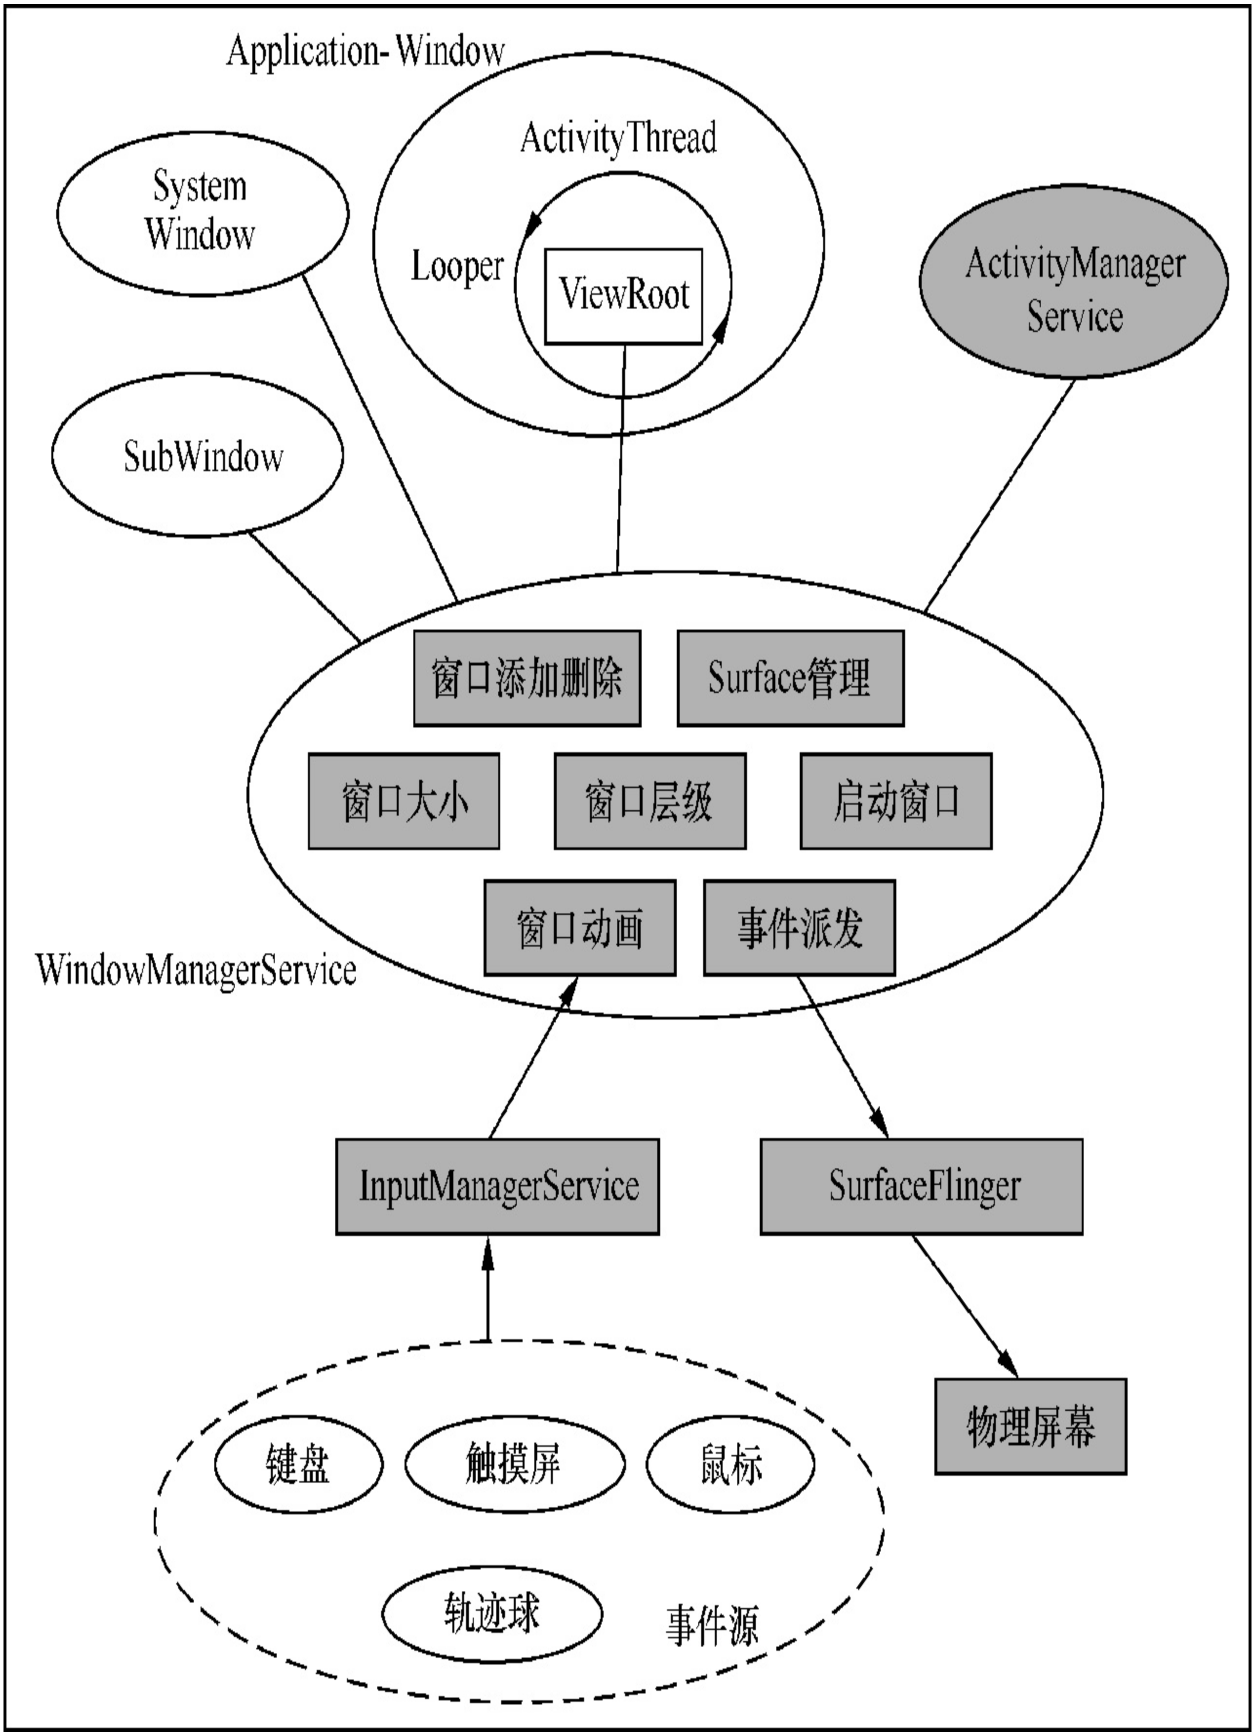
Application-Window
ActivityThread
System Window
Looper
ViewRoot
ActivityManager Service
SubWindow
窗口添加删除
Surface管理
窗口大小
窗口层级
启动窗口
窗口动画
事件派发
WindowManagerService
InputManagerService
SurfaceFlinger
物理屏幕
键盘
触摸屏
鼠标
轨迹球
事件源

▲图10-1　WindowManagerService的设计漫想

从图中可知，要实现完整的窗口管理器，所涉及的元素最少应包括以下几个。

1．WindowManagerService(WMS)

WMS将以什么样的形态来提供服务呢？没错，和AMS等Service一样，WMS也会是系统级服务的一部分。细化而言，它应该具有如下属性。

- 由SystemServer负责启动

这就意味着WMS的启动时机相对较晚。聪明的读者一定会问，那么在WMS还没有运行之前，终端显示屏上难道就“一团黑”？当然不是。因为在WMS启动前系统只需要显示开机画面，而它们都有特殊的方式来向屏幕输出图像。比如前一章中介绍的开机动画，就是由BootAnimation直接通过OpenGL ES与SurfaceFlinger的配合来完成的。这也从侧面告诉我们，要想在Android中显示UI界面，并不一定要通过WMS——我们完全可以模拟BootAnimation来写一个不基于WMS的Linux应用程序，有兴趣的读者可以尝试下。

- 直到系统关机时才能退出

这很容易理解——如果“导演”都不在了，那整台话剧自然也就乱了。

- 发生异常时必须能自动重启

是软件就难免有Bug。如果WMS不幸发生了异常，后果将非常严重。所以要求它必须具备发生异常时重启的功能。

2．SurfaceFlinger

前面我们分析了SurfaceFlinger与WMS的关系，从中可以推测出两者间必定会有不少交集，后续小节会有详细分析。

3．有图形显示需求的程序

除了常见的以Activity组件所构成的应用程序外，Android系统自身也有界面显示的需求。可想而知，不同类型的用户所创建的窗口是有优先级的。比如：

- Application Window

针对普通应用程序的显示申请所产生的窗口。和系统窗口相比，它们的窗口“层级值”比较低。

- System Window

比如顶部的系统状态栏、壁纸等都属于系统窗口。

- Sub Window

这种类型的窗口也称为子窗口，所以它的属性很大程度上受限于其父窗口。比如我们点击Menu时出现的应用程序菜单，就是在原来窗口的基础上弹出来的。

……

后续小节会详细描述所有类型窗口的“层级值”分配。

4．InputManagerService(IMS)

WMS是派发系统按键和触摸消息这一“重任”的最佳“人”选。当IMS收到一个按键或者触摸事件时，它需要寻找一个最合适的“窗口”来处理消息；而WMS是窗口的管理者，系统中所有窗口的状态和信息都在其掌控中，完成这一工作“不在话下”。

5．ActivityManagerService (AMS)

AMS和WMS之间也有交互。AMS是管理系统中所有Activity的“大总管”，而Activity状态的变化通常会带来“界面”上的改变。举个例子，假设Activity1启动了Activity2，那么体现到界面上的变化就是Activity1逐步淡出（窗口动画效果，后续小节有讲解）显示，而后

Activity2描述的UI界面占据屏幕。

6．Binder通信

无论是SurfaceFlinger，AMS或者应用进程，它们与WMS间都需要进行Binder通信。面对不同的设计需求，Binder也会有各种样式上的变异。不过“万变不离其宗”，如果读者对这些基础知识还不清楚，建议先回头复习一下进程/线程和Binder相关章节的内容，然后再来看WMS中对它们的应用。

从WindowManagerService的内部实现来讲，它需要包含如下子功能。

- 窗口的添加与删除

当某个进程（无论是普通应用程序或者系统进程）有显示需求时，它可以请求WMS添加一个窗口，并于不再需要显示时移除该窗口。

- 启动窗口

当我们增加一个新窗口时，在某些条件下需要添加一个“启动窗口”，后续小节有详细分析。

- 窗口动画

当窗口间切换时，采用“窗口动画”可以加强UI特效，让你的产品看起来更“炫”。窗口动画是允许定制的。

- 窗口大小

Android系统支持显示不同尺寸大小的窗口，如StatusBar就只是屏幕最顶层的一条“Bar”；类似的还有对话框、悬浮窗等，这些窗口的大小设定与管理都需要由WMS完成。

- 窗口层级

即Z-Order，在SurfaceFlinger中我们已经看到了它对于最终显示结果的影响。不过Surface Flinger只是“摄像机”，它负责客观地拍

摄当前场景；而各窗口Z-Order的调整则是由WMS来完成的。

- 事件派发

  事件派发也是WMS一个必不可少的功能。

10.1.1 WMS的启动

我们说过，WMS属于SystemServer启动众多系统服务中的一种：

```
/*frameworks/base/services/java/com/android/server/SystemServer.j
public void run() {
   ….
   Slog.i(TAG, "Window Manager");
   wm = WindowManagerService.main(context, power, display, inputM
         factoryTest != SystemServer.FACTORY_TEST_LOW_LEVEL,!firs
   ServiceManager.addService(Context.WINDOW_SERVICE, wm);/*注册到S
                        其他进程可以利用Context.WINDOW_SERVICE即“win
```

它提供了一个静态的main函数，真正的创建工作是在这里面实现的。具体源码分析可以参见本书“Android进程/线程管理”章节中的“Thread休眠和唤醒”，这里不再赘述。

这样WMS服务就成功地启动起来了，而且其他进程也可以通过向ServiceManager查询“window”来获取它的服务。接下来的小节我们会分析WMS提供了哪些接口功能。

10.1.2 WMS的基础功能

WMS使用AIDL的方式来描述它的接口。关于使用AIDL生成的Binder Server与手工Binder Server的区别，我们在前面章节已经详细分析过，不清楚的读者可以回头复习一下。在未进行编译的情况下，源码中只能找到IWindowManager.aidl。而后这个文件会被AIDL工具转化为IWindowManager.java：

```
/*frameworks/base/core/java/android/view/IWindowManager.aidl*/
interface IWindowManager
{…
    IWindowSession openSession(in IInputMethodClient client, in I
    inputContext); /*与WMS建立一个Session连接，有点类似于SurfaceFlinge
    boolean inputMethodClientHasFocus(IInputMethodClient client);
```

```
    void getInitialDisplaySize(int displayId, out Point size);/*下
    void getBaseDisplaySize(int displayId, out Point size);
    void setForcedDisplaySize(int displayId, int width, int heigh
    …
    boolean hasSystemNavBar();
    …
    void addWindowToken(IBinder token, int type);//后面一个小节会解释
    void removeWindowToken(IBinder token);
    void addAppToken(int addPos, IApplicationToken token,
          int groupId, int requestedOrientation, boolean fullscre
    …
    void prepareAppTransition(int transit, boolean alwaysKeepCurr
    int getPendingAppTransition();
    void overridePendingAppTransition(String packageName, int ent
                         IRemoteCallback startedCallback);
    void overridePendingAppTransitionScaleUp(int startX, int star
    startHeight);
    …
    void setAppStartingWindow(IBinder token, String pkg, int them
          in CompatibilityInfo compatInfo, CharSequence nonLocali
          int icon, int windowFlags, IBinder transferFrom, boolea
          /*启动窗口*/
    void setAppWillBeHidden(IBinder token);
    void setAppVisibility(IBinder token, boolean visible);/*当App
                                                       整界面显示
    …
    void updateRotation(boolean alwaysSendConfiguration,boolean f
                                                       旋转有关的
    int getRotation();
    int watchRotation(IRotationWatcher watcher);
    void removeRotationWatcher(IRotationWatcher watcher);
    …
    Bitmap screenshotApplications(IBinder appToken, int displayId
    maxHeight);/*屏幕截图*/
    void statusBarVisibilityChanged(int visibility);/*Status bar通
    …
}
```

上面代码段节选了WMS提供的部分重要接口，以此让大家有个直观的印象。从中可以了解到WMS所要完成的“功能”既多且杂——比如获得显示屏的尺寸大小、判断是否有System Bar、是否有Navigation Bar、锁定屏幕、截取屏幕等。

10.1.3 WMS的工作方式

WMS是Android中一个非常重要的系统服务，内部实现也相对复杂。对于初学者来说可能会找不到“入手”的地方，因而我们可以先把它的工作方式作为学习的切入点，如图10-2所示。

WMS的工作方式在几个Jelly Bean版本中（4.1～4.3）差异还是比较大的。4.1版本中，当SystemServer调用WindowManagerService.main时（仍然是运行在SystemServer自己的线程中的），它会创建一个WMThread来作为WMS独立的服务线程——我们称之为WMS的主线程。当主线程成功运行后，SystemServer才能从main函数返回并继续做其他操作。同时，WMS的主线程则进入循环中，即Looper。

4.1版本以后的WMS工作方式逐步发生了改变，其中最显著的一个就是WMThread不复存在，取而代之的是SystemServer中的wmHandlerThread。这样的设计使得SystemServer中的其他Service也可以往wmHandlerThread中投递事件，从而便捷地获取WMS的服务。另外，WMS中接收到的大部分服务请求都是由跨进程的对象产生的（我们在上图中把它们统一命名为“调用者”），如InputManagerService、各应用进程等。这些调用者通过以下两种典型的方式，源源不断地将外部用户的请求和状态反馈给WMS。

- 事件投递

既然WMS有自己运行的主线程，那么通常情况下外界的请求或者事件只要投递到这个线程的队列中即可。具体而言，当wmHandlerThread创建一个WindowManagerService对象时，后者的mH成员变量将与wmHandlerThread产生关联。而后如果调用者通过IWindowManager提供的接口来获取服务时，就可以利用mH来把消息投递到wmHandlerThread所属的消息队列中。这就是事件投递的方法。

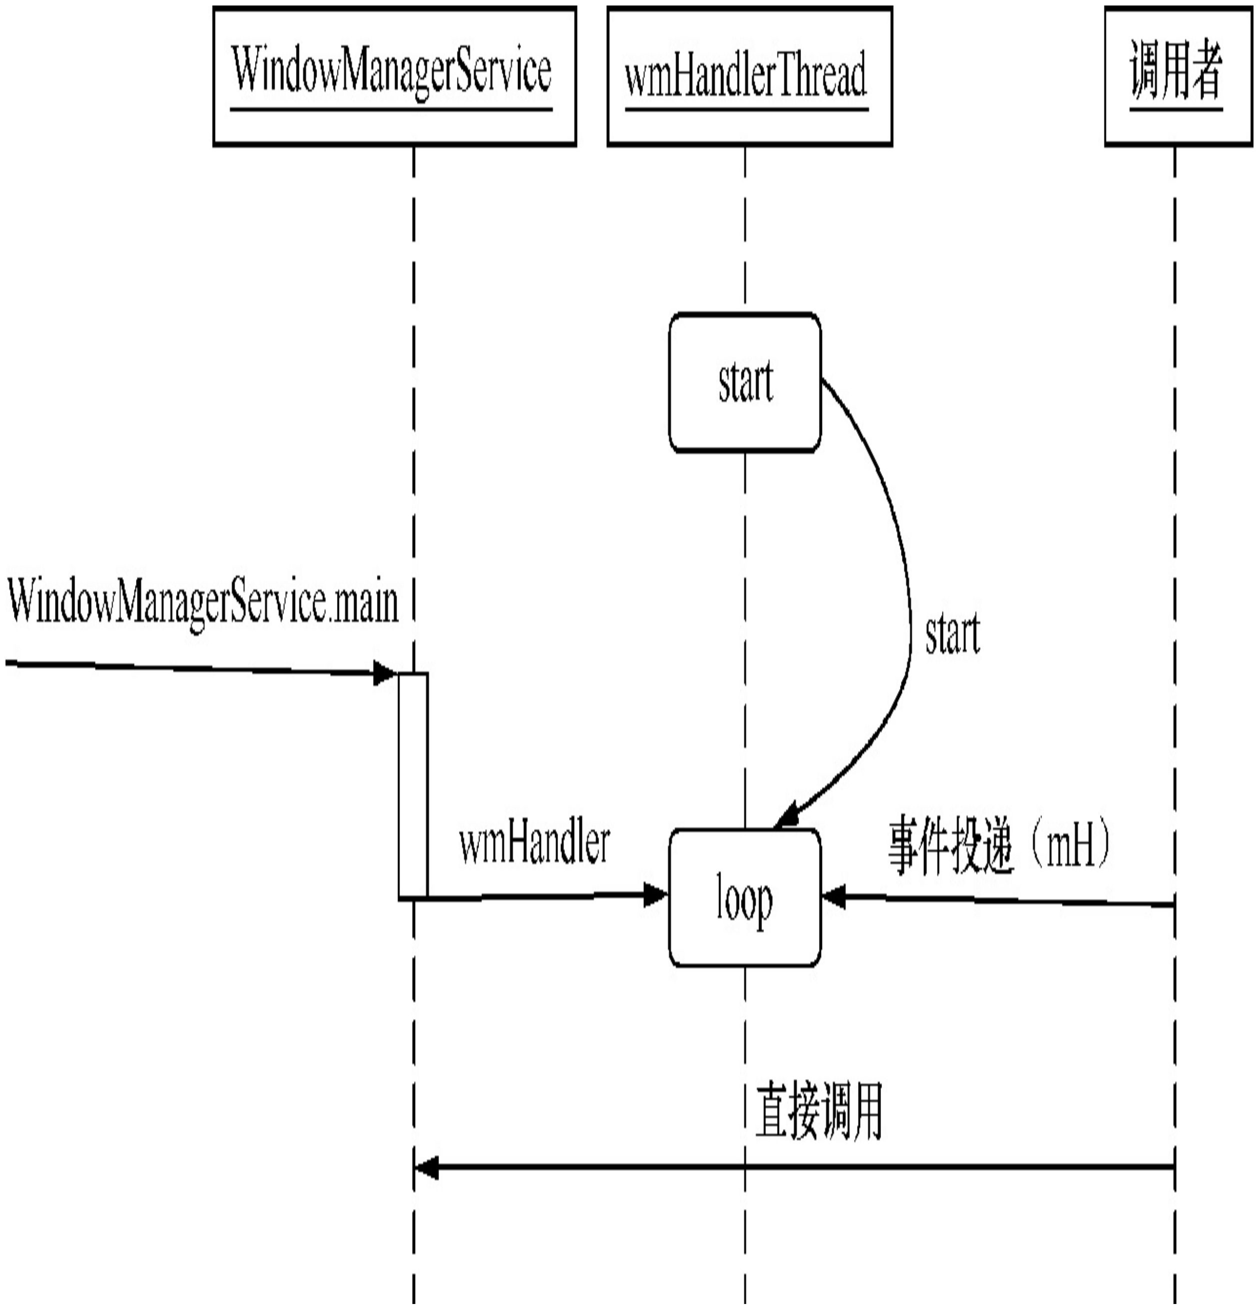

▲图10-2　WMS工作方式简图

- 直接调用

我们在进程章节讲述Handler和MessageQueue的关系时，曾举过一个借钱的例子：如果这一事件（借钱）不是非常着急的话，可以先排队再处理；反之，如果是刻不容缓的事件，就需要当即处理。WMS同样也存在这样的工作方式——不过要特别注意，此时事件的处理过程仍然运

行在事件产生者自己的线程中。

比如下面的isKeyguardLocked就直接调用了WMS的内部实现，而没有先将事件入队：

```
public boolean isKeyguardLocked() {
    return mPolicy.isKeyguardLocked();
}
```

另一个接口showStrictModeViolation则是通过事件投递的方式实现的：

```
public void showStrictModeViolation(boolean on) {
    if (mHeadless) return;
    int pid = Binder.getCallingPid();
    mH.sendMessage(mH.obtainMessage(H.SHOW_STRICT_MODE_VIOLAT
}
```

10.1.4　WMS，AMS与Activity间的联系

一个Activity在启动过程中，需要多个系统服务的支持——而其中最主要的就是AMS和WMS。我们从两个方面来考查这三者的关系。

1．IPC通信

Activity运行在应用程序进程中，而AMS和WMS则运行在系统相关进程中，它们之间的通信需要Binder的支持。从这个角度来看，它们之间的关系如图10-3所示。

Activity与AMS的进程间通信实现，我们在ActivityManagerService章节有详细分析，这里不再赘述。另外，因为WMS与AMS实际上是驻留在同一个进程中的（它们都由SystemServer启动），所以理论上是可以直接进行函数调用的。比如SystemServer就通过ActivityManager Service.self().setWindowManager(wm)来将WindowManagerService.main的结果传递给AMS；而WMS虽然是通过ActivityManagerNative.getDefault()来取得一个IActivityManager对象，但根据Binder驱动的实现原理，它实际上得到的也是AMS对象的内存地址。如果读者觉得这部分知识还不是很清楚，建议回头复习下Binder章节。

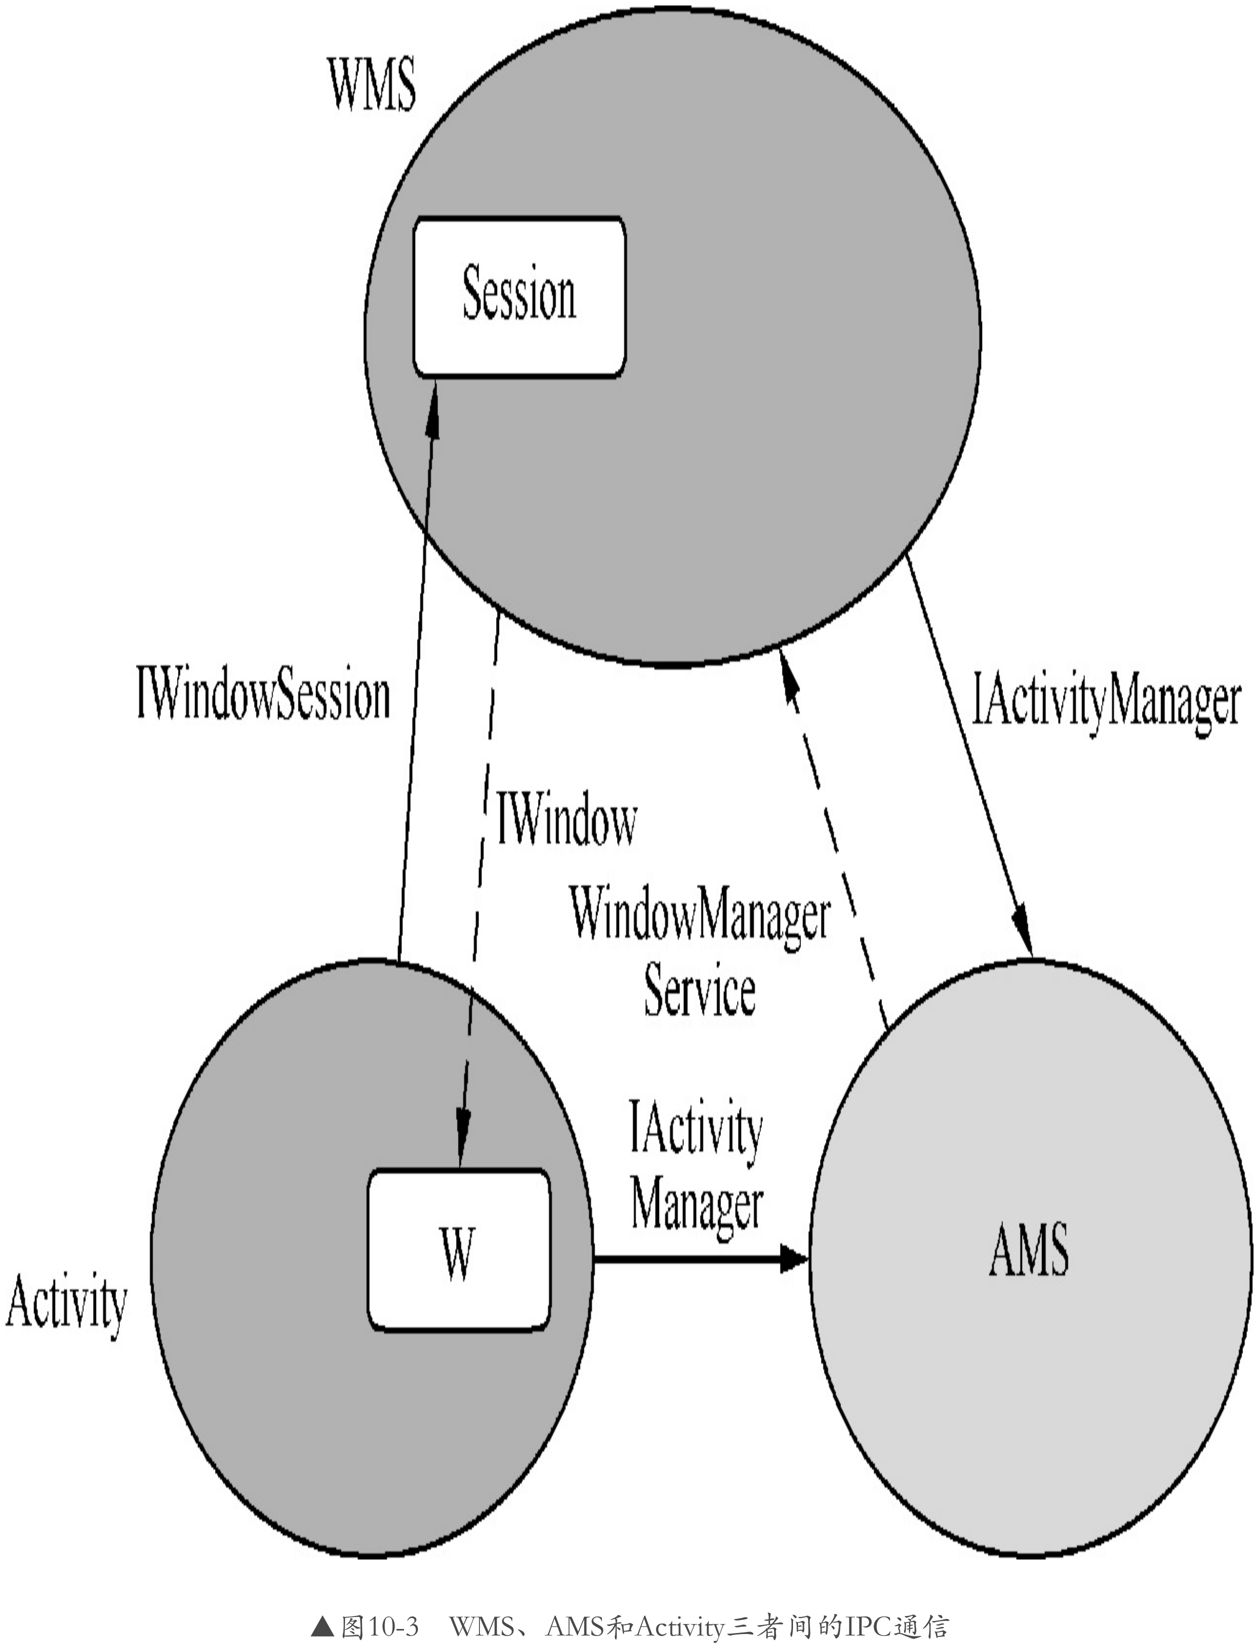

▲图10-3　WMS、AMS和Activity三者间的IPC通信

应用程序访问WMS的服务首先当然得通过ServiceManager，因为WMS

是实名Binder Server；除此之外，WMS还需要针对每个Activity提供另一种匿名的实现，即IWindowSession——这有点类似于SurfaceFlinger中的Client。WMS和SurfaceFlinger是面向系统中所有应用程序服务的，如果客户的任何“小请求”都需要直接通过它们来处理，那么无疑会加重两者的负担，进而影响到系统的整体响应速度。所以WMS通过IWindowManager::openSession()向外界开放一个打开Session的接口，然后客户端的一些“琐碎”杂事就可以找Session解决了。比如ViewRoot在构造时就会调用这个函数：

```
/*frameworks/base/core/java/android/view/ViewRootImpl.java*/
public ViewRootImpl(Context context) {…
    mWindowSession = WindowManagerGlobal.getWindowSession();//获取
    …
}
/*frameworks/base/core/java/android/view/WindowManagerGlobal.java
    public static IWindowSession getWindowSession() {
        synchronized (WindowManagerGlobal.class) {
            if (sWindowSession == null) {
                try {…
                    IWindowManager windowManager = getWindowManag
                    sWindowSession = windowManager.openSession(
                            imm.getClient(), imm.getInputContext(
    …
```

ISession在Server端的实现是Session，后续我们会进行更详细的讲解。

那么，WMS如何访问应用程序呢？

这也是由匿名Binder来完成的。在应用程序进程中，它首先通过openSession来建立与WMS的“私有连接”。紧接着它会调用IWindowSession::relayout(IWindow window,…)——这个函数的第一个参数就是由应用程序提供的，用于WMS回访应用进程的匿名Binder Server。IWindow在应用进程中的实现是W类：

```
static class W extends IWindow.Stub {…
```

W提供了包括resized，dispatchAppVisibility，dispatchScreenState在内的一系列回调接口，用于WMS实时通知应用进程界面上的变化（有些变化并不是应用进程的主动意愿）。

2. 内部组织方式

当一个新的Activity被启动时（startActivity），它首先需要在AMS中注册——此时AMS会在内部生成一个ActivityRecord来记录这个Activity；另外因为Activity是四大组件中专门用于UI显示的，所以WMS也会对它进行记录——以WindowState来表示。

所以从服务内部组织方式的角度来讲，三者的关系如图10-4所示。

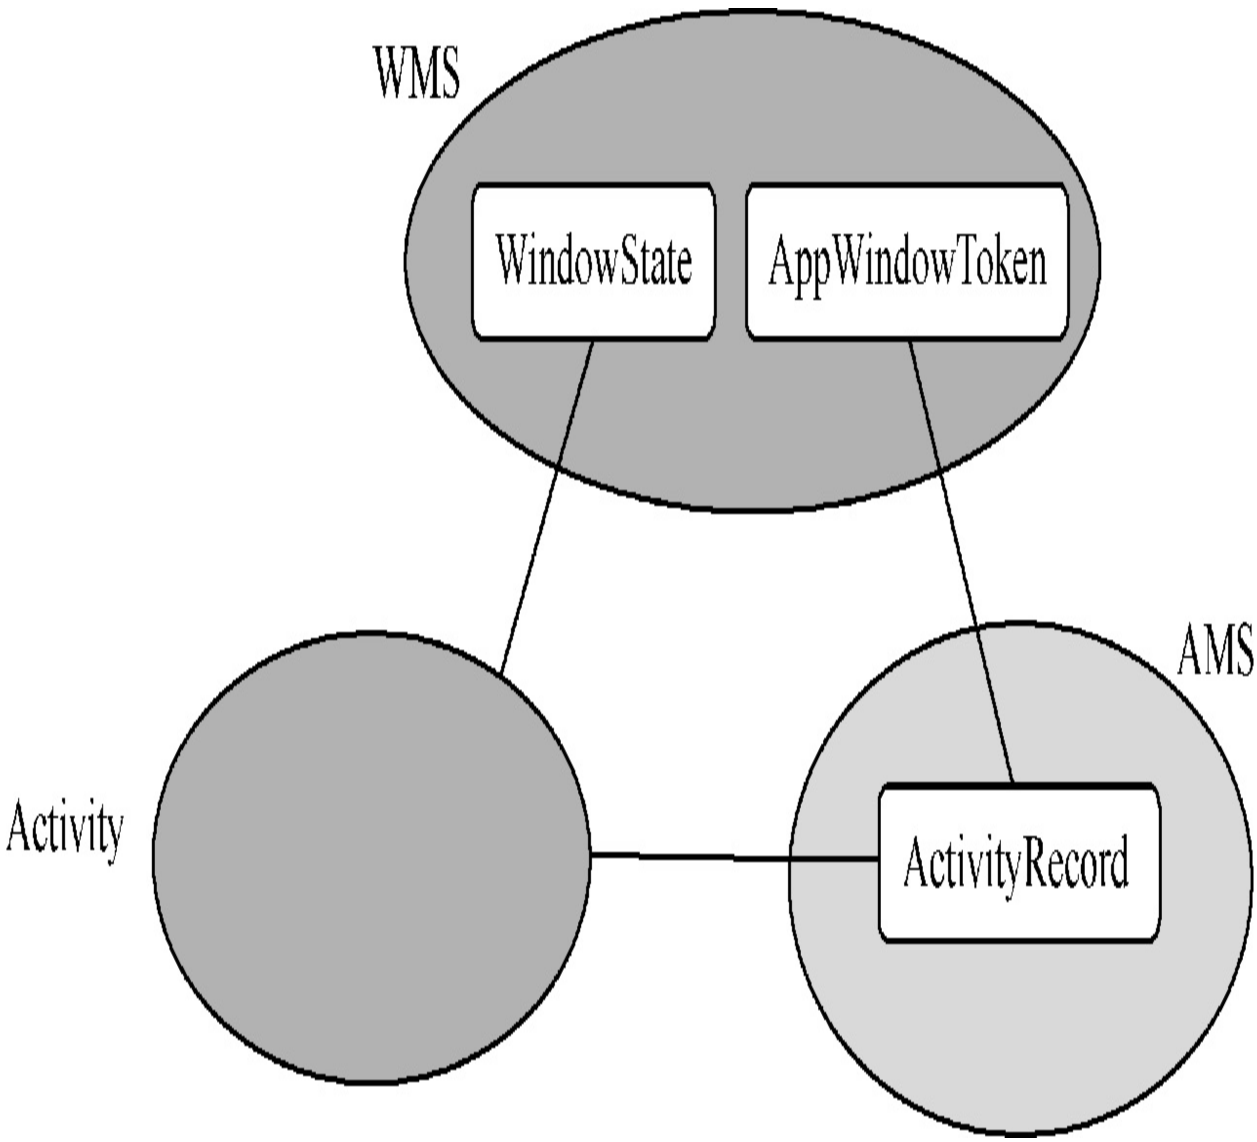

▲图10-4　Activity在AMS和WMS中的组织和管理

如图所示，WMS除了利用WindowState来保存一个“窗口”相关的信

息外，还使用AppWindowToken来对应AMS中的一个ActivityRecord。这样三者间就形成非常紧密的联系，为窗口的显示与管理打下了坚实的基础。

10.2　窗口属性

10.2.1　窗口类型与层级

Android支持的窗口类型很多，不过我们可以将它们统一划分为三大类，即Application Window，System Window和Sub Window。另外各个种类下还细分为若干子类型，且都在WindowManager.java中定义，如下所示。

1．Application Window

普通应用程序的窗口都属于这一类，如表10-1所示。

表10-1　Application Window细分

Type	Description
FIRST_APPLICATION_WINDOW= 1	应用程序窗口类型的起始值
TYPE_BASE_APPLICATION= 1	应用程序窗口类型的基础值，其他窗口类型以此为基础
TYPE_APPLICATION= 2	普通应用程序的窗口类型
TYPE_APPLICATION_STARTING= 3	应用程序的启动窗口类型。它不能由应用程序本身使用，而是Android系统为应用程序启动前设计的窗口——当真正的应用窗口启动后就消失了

LAST_APPLICATION_WINDOW=99	应用程序窗口类型的最大值

2．Sub Window

从“Sub Window”的字面意思可以了解到，这类窗口将附着在其他Window中，因而被称为“子窗口”。具体包括如下子类型，如表10-2所示。

表10-2　Sub Window细分

Type	Description
FIRST_SUB_WINDOW=1000	子窗口类型的起始值
TYPE_APPLICATION_PANEL=FIRST_SUB_WINDOW	应用程序的panel子窗口 的父窗口之上显示
TYPE_APPLICATION_MEDIA=FIRST_SUB_WINDOW+1	用于显示多媒体内容的 口，位于父窗口之下
TYPE_APPLICATION_SUB_PANEL=FIRST_SUB_WINDOW+2	也是一种panel子窗口， 窗口以及所有 TYPE_APPLICATION_ 子窗口之上
TYPE_APPLICATION_ATTACHED_DIALOG=FIRST_SUB_WINDOW+3	Dialog子窗口，如menu

TYPE_APPLICATION_MEDIA_OVERLAY= FIRST_SUB_WINDOW+4	多媒体窗口的覆盖层， TYPE_APPLICATION_ 和应用程序窗口之间， 要是透明的才有意义。 类型处于未开放状态
LAST_SUB_WINDOW= 1999	子窗口类型的结束值

3．System Window

系统程序所采用的窗口类型，细分如表10-3所示。

表10-3　System Window细分

Type	Description
FIRST_SYSTEM_WINDOW = 2000;	系统窗口的起始值
TYPE_STATUS_BAR = FIRST_SYSTEM_WINDOW;	系统状态栏窗口
TYPE_SEARCH_BAR = FIRST_SYSTEM_WINDOW+1;	搜索条窗口
TYPE_PHONE= FIRST_SYSTEM_WINDOW+2;	通话窗口，特别是来电通话。通常情况下它位于系统状态栏之下，其他应用程序窗口之上
TYPE_SYSTEM_ALERT =	Alert窗口，如电量不足的警

FIRST_SYSTEM_WINDOW+3;	告窗口。通常都位于所有其他应用程序之上
TYPE_KEYGUARD = FIRST_SYSTEM_WINDOW+4;	屏保窗口
TYPE_TOAST = FIRST_SYSTEM_WINDOW+5;	短暂的提示框窗口
TYPE_SYSTEM_OVERLAY = FIRST_SYSTEM_WINDOW+6;	系统覆盖层窗口，这种类型的窗口不能接收input焦点，否则会与屏保发生冲突
TYPE_PRIORITY_PHONE = FIRST_SYSTEM_WINDOW+7;	电话优先窗口，如屏保状态下显示来电窗口
TYPE_SYSTEM_DIALOG = FIRST_SYSTEM_WINDOW+8;	比如RecentAppsDialog就是这种类型的窗口
TYPE_KEYGUARD_DIALOG = FIRST_SYSTEM_WINDOW+9;	屏保时显示的对话框
TYPE_SYSTEM_ERROR = FIRST_SYSTEM_WINDOW+10;	系统错误窗口
TYPE_INPUT_METHOD = FIRST_SYSTEM_WINDOW+11;	输入法窗口

TYPE_INPUT_METHOD_DIALOG = FIRST_SYSTEM_WINDOW+12;	输入法窗口之上的对话框式窗口
TYPE_WALLPAPER = FIRST_SYSTEM_WINDOW+13;	壁纸窗口
TYPE_STATUS_BAR_PANEL = FIRST_SYSTEM_WINDOW+14;	滑动状态栏出现的窗口
TYPE_SECURE_SYSTEM_OVERLAY= FIRST_SYSTEM_WINDOW+15; TYPE_DRAG= FIRST_SYSTEM_WINDOW+16; TYPE_STATUS_BAR_SUB_PANEL= FIRST_SYSTEM_WINDOW+17; TYPE_POINTER= FIRST_SYSTEM_WINDOW+18; 3种类型	暂未开放
TYPE_NAVIGATION_BAR = FIRST_SYSTEM_WINDOW+19;	导航条，可以参见本书应用篇的System UI章节
TYPE_VOLUME_OVERLAY = FIRST_SYSTEM_WINDOW+20;	系统音量条
TYPE_BOOT_PROGRESS = FIRST_SYSTEM_WINDOW+21;	启动时的进度条窗口
TYPE_HIDDEN_NAV_CONSUMER = FIRST_SYSTEM_WINDOW+22;	当导航条隐藏时用于消耗触摸事件的伪窗口

TYPE_DREAM= FIRST_SYSTEM_WINDOW+23; TYPE_NAVIGATION_BAR_PANEL= FIRST_SYSTEM_WINDOW+24;	暂未开放
TYPE_UNIVERSE_BACKGROUND = FIRST_SYSTEM_WINDOW+25;	在多用户系统中，将显示给所有用户
TYPE_DISPLAY_OVERLAY = FIRST_SYSTEM_WINDOW+26;	用于模拟第二个显示设备
TYPE_MAGNIFICATION_OVERLAY = FIRST_SYSTEM_WINDOW+27;	有点类似于“放大镜”的效果，用于放大显示某部分内容
TYPE_RECENTS_OVERLAY = FIRST_SYSTEM_WINDOW+28;	与TYPE_SYSTEM_DIALOG基本一致，区别是TYPE_RECENTS_OVERLAY只显示在一个用户的屏幕上
LAST_SYSTEM_WINDOW = 2999;	系统窗口结束

每种子类型后面都有一个数值，代表了它的窗口类型值。比如TYPE_STATUS_BAR= FIRST_SYSTEM_WINDOW=2000。三大窗口类型的间隔是:

```
Application Window: 1-99
Sub Window: 1000-1999
System Window: 2000-2999
```

当某个进程向WMS申请一个窗口时，它需要指定所需的窗口类型

（注意：除个别特殊情况外应用程序是不能创建系统窗口的，因为系统会做权限检查）。然后WMS根据用户申请的窗口类型以及当前系统中已有窗口的情况来给它分配一个最终的“层级值”（这是根据窗口类型值计算出来的，后续有详细说明）。

系统在运行期间，很可能会有多个窗口属于同一种窗口类型。比如当前有3个应用程序在执行，那么类型为TYPE_APPLICATION的应用程序窗口至少就会有3个。因而WMS需要根据具体情况来调整它们的最终“层级值”。数值越大的窗口，其在WMS中的优先级越高，最终在屏幕上显示时就越靠近用户。我们来看看具体的分配规则：

```
/*frameworks/base/services/java/com/android/server/wm/WindowManag
private final void assignLayersLocked(WindowList windows) {
        int N = windows.size(); //当前系统中所有窗口的个数
        int curBaseLayer = 0;//根据上面所说的“窗口类型值”计算出来的，后面
        int curLayer = 0;//层值
        int i;
            …
        for (i=0; i<N; i++) {
            final WindowState w = mWindows.get(i);
            final WindowStateAnimator winAnimator = w.mWinAnimato
            boolean layerChanged = false;
            int oldLayer = w.mLayer;
            if (w.mBaseLayer == curBaseLayer || w.mIsImWindow
                   || (i > 0 && w.mIsWallpaper)) {/*这个窗口的“基础
                                                 不是一样的*/
               curLayer += WINDOW_LAYER_MULTIPLIER;/*同一“基础层级”
               w.mLayer = curLayer;
            } else {/*窗口的“基础层级”值变了*/
               curBaseLayer = curLayer = w.mBaseLayer;/*curBaseLa
               w.mLayer = curLayer;
            }
            if (w.mLayer != oldLayer) {
               layerChanged = true;
               anyLayerChanged = true;
            }
            …
        }…
    }
```

这个函数的计算前提是windows里的所有窗口都是按照mBaseLayer有序排列的。当for循环第一次执行时，因为curBaseLayer=curLayer=0，所以w.mBaseLayer不等于curBaseLayer，从而curBaseLayer=curLayer=w.mBaseLayer。而下一轮循环中，取决于

该WindowState的mBaseLayer。如果它和上次相同，就证明是同一种类型的窗口，因而只要curLayer+=WINDOW_LAYER_MULTIPLIER（值为5。窗口间的间隔设为5，而不是1，是为后期可能有的effect surface做准备）即可，也就是在原来Layer值的基础上加上5；如果不相同的话，说明又是另一种类型。因而当前curBaseLayer的值就是w.mBaseLayer，而且curBaseLayer=curLayer=w.mBaseLayer——如此循环往复，直到处理完windows中的所有窗口。

那么mBaseLayer是什么，它和前面所说的“窗口类型值”有什么关联？因为mBaseLayer是WindowState的成员变量，我们从它的构造函数入手：

```
/*frameworks/base/services/java/com/android/server/wm/WindowState
WindowState(…WindowManager.LayoutParams a,…) {…
    if ((mAttrs.type >= FIRST_SUB_WINDOW &&mAttrs.type <= LAST_SU
        mBaseLayer = mPolicy.windowTypeToLayerLw(attachedWindow.m
  WindowManagerService.TYPE_LAYER_MULTIPLIER+ WindowManagerServic
        mSubLayer = mPolicy.subWindowTypeToLayerLw(a.type);
        …
    } else {
        mBaseLayer = mPolicy.windowTypeToLayerLw(a.type)
                    * WindowManagerService.TYPE_LAYER_MULTIPLIER
                    + WindowManagerService.TYPE_LAYER_OFFSET;
        mSubLayer = 0;
        …
    }
}
```

由上述代码段可知，所有类型窗口的BaseLayer值都可以由以下几步取得。

Step1．windowTypeToLayerLw，该函数针对不同的窗口类型做了简单的映射。具体的映射规则取决于该设备所采用的WindowManagerPolicy。比如，PhoneWindowManager中的映射如表10-4所示。

表10-4　windowTypeToLayerLw对照表（PhoneWindowManager）

WINDOW TYPE	LAYER

[FIRST_APPLICATION_WINDOW, LAST_APPLICATION_WINDOW]	LAST_APPLICATION_WINDOW
TYPE_WALLPAPER	WALLPAPER_LAYER
TYPE_PHONE	PHONE_LAYER
TYPE_SEARCH_BAR	SEARCH_BAR_LAYER
TYPE_SYSTEM_DIALOG	SYSTEM_DIALOG_LAYER
TYPE_TOAST	TOAST_LAYER
TYPE_PRIORITY_PHONE	PRIORITY_PHONE_LAYER
TYPE_SYSTEM_ALERT	SYSTEM_ALERT_LAYER
TYPE_INPUT_METHOD	INPUT_METHOD_LAYER
TYPE_INPUT_METHOD_DIALOG	INPUT_METHOD_DIALOG_LAY
TYPE_KEYGUARD	KEYGUARD_LAYER
TYPE_KEYGUARD_DIALOG	KEYGUARD_DIALOG_LAYER

TYPE_DREAM	SCREENSAVER_LAYER
TYPE_STATUS_BAR_SUB_PANEL	STATUS_BAR_SUB_PANEL_LA
TYPE_STATUS_BAR	STATUS_BAR_LAYER
TYPE_STATUS_BAR_PANEL	STATUS_BAR_PANEL_LAYER
TYPE_VOLUME_OVERLAY	VOLUME_OVERLAY_LAYER
TYPE_SYSTEM_OVERLAY	SYSTEM_OVERLAY_LAYER
TYPE_NAVIGATION_BAR	NAVIGATION_BAR_LAYER
TYPE_NAVIGATION_BAR_PANEL	NAVIGATION_BAR_PANEL_LA
TYPE_SYSTEM_ERROR	SYSTEM_ERROR_LAYER
TYPE_DRAG	DRAG_LAYER
TYPE_SECURE_SYSTEM_OVERLAY	SECURE_SYSTEM_OVERLAY_
TYPE_BOOT_PROGRESS	BOOT_PROGRESS_LAYER
TYPE_POINTER	POINTER_LAYER

TYPE_HIDDEN_NAV_CONSUMER	HIDDEN_NAV_CONSUMER_LA

对于Sub Window而言，窗口类型取决于其父窗口的类型。

Step2. 上一步所得的“映射值”需要乘以TYPE_LAYER_MULTIPLIER(10000)。这是因为系统运行过程中很可能出现同种类型的多个窗口，所以应该有一个足够大的间隔来供分配。

Step3. 最后，还要加上偏移值TYPE_LAYER_OFFSET(1000)。根据代码注释，这个偏移值是为了移动同一层级的一整组窗口而设计的。

Step4. 对于子窗口类型而言，还要特别计算mSubLayer值。子窗口与父窗口有着紧密的联系，因而mSubLayer其实是用于决定这个子窗口应该“偏移”父窗口的数值大小。比如TYPE_APPLICATION_PANEL和TYPE_APPLICATION_ATTACHED_DIALOG类型的子窗口对应的mSubLayer都是APPLICATION_PANEL_SUBLAYER=1；而 TYPE_APPLICATION_MEDIA类型的子窗口对应的mSubLayer则是APPLICATION_MEDIA_SUBLAYER=-2。子窗口在显示时既有可能在父窗口之上，也有可能在其之下。

10.2.2 窗口策略（Window Policy）

前一小节计算windowTypeToLayerLw时，我们曾提到WindowManagerPolicy。

那么，什么是Window Policy？从字面来理解，它是“窗口的策略/方针”。应用到WMS中，则代表了Android显示系统所遵循的统一的窗口显示规则。针对不同的产品，策略通常是不一样的。

举个例子，大部分手机设备有Status Bar；而平板电脑虽然没有Status Bar，但有Combined Bar。这些“界面特征”构成了一款特定产品共同的UI属性，因而有必要做统一的控制——这就是Window Policy的作用。

Android系统从设计之初就不是只面向单一类型产品的。只不过它的某些行为天生的更接近于某种产品而已，如Phone或者Tablet。换句话说，各开发商完全可以依据具体的设备需求来定制出符合自己产品特

性的Window Policy。

Android源码实现中，与Window Policy相关的类主要有4个，即WindowManagerPolicy，PhoneWindowManager，PolicyManager和Policy。个人感觉这些类的命名并不是很合理，容易造成误解。先来看PolicyManager中提供的如下两个函数。

- makeNewWindow

产生一个Window。“窗口”是一个抽象的概念，它表示一个UI显示的管理单元。当前系统中默认情况下产生的是一个PhoneWindow，也就是针对手机设备的窗口。

- makeNewWindowManager

这个接口应该叫作makeNewWindowManagerPolicy，它产生一个管理Window的Policy，如图10-5所示。

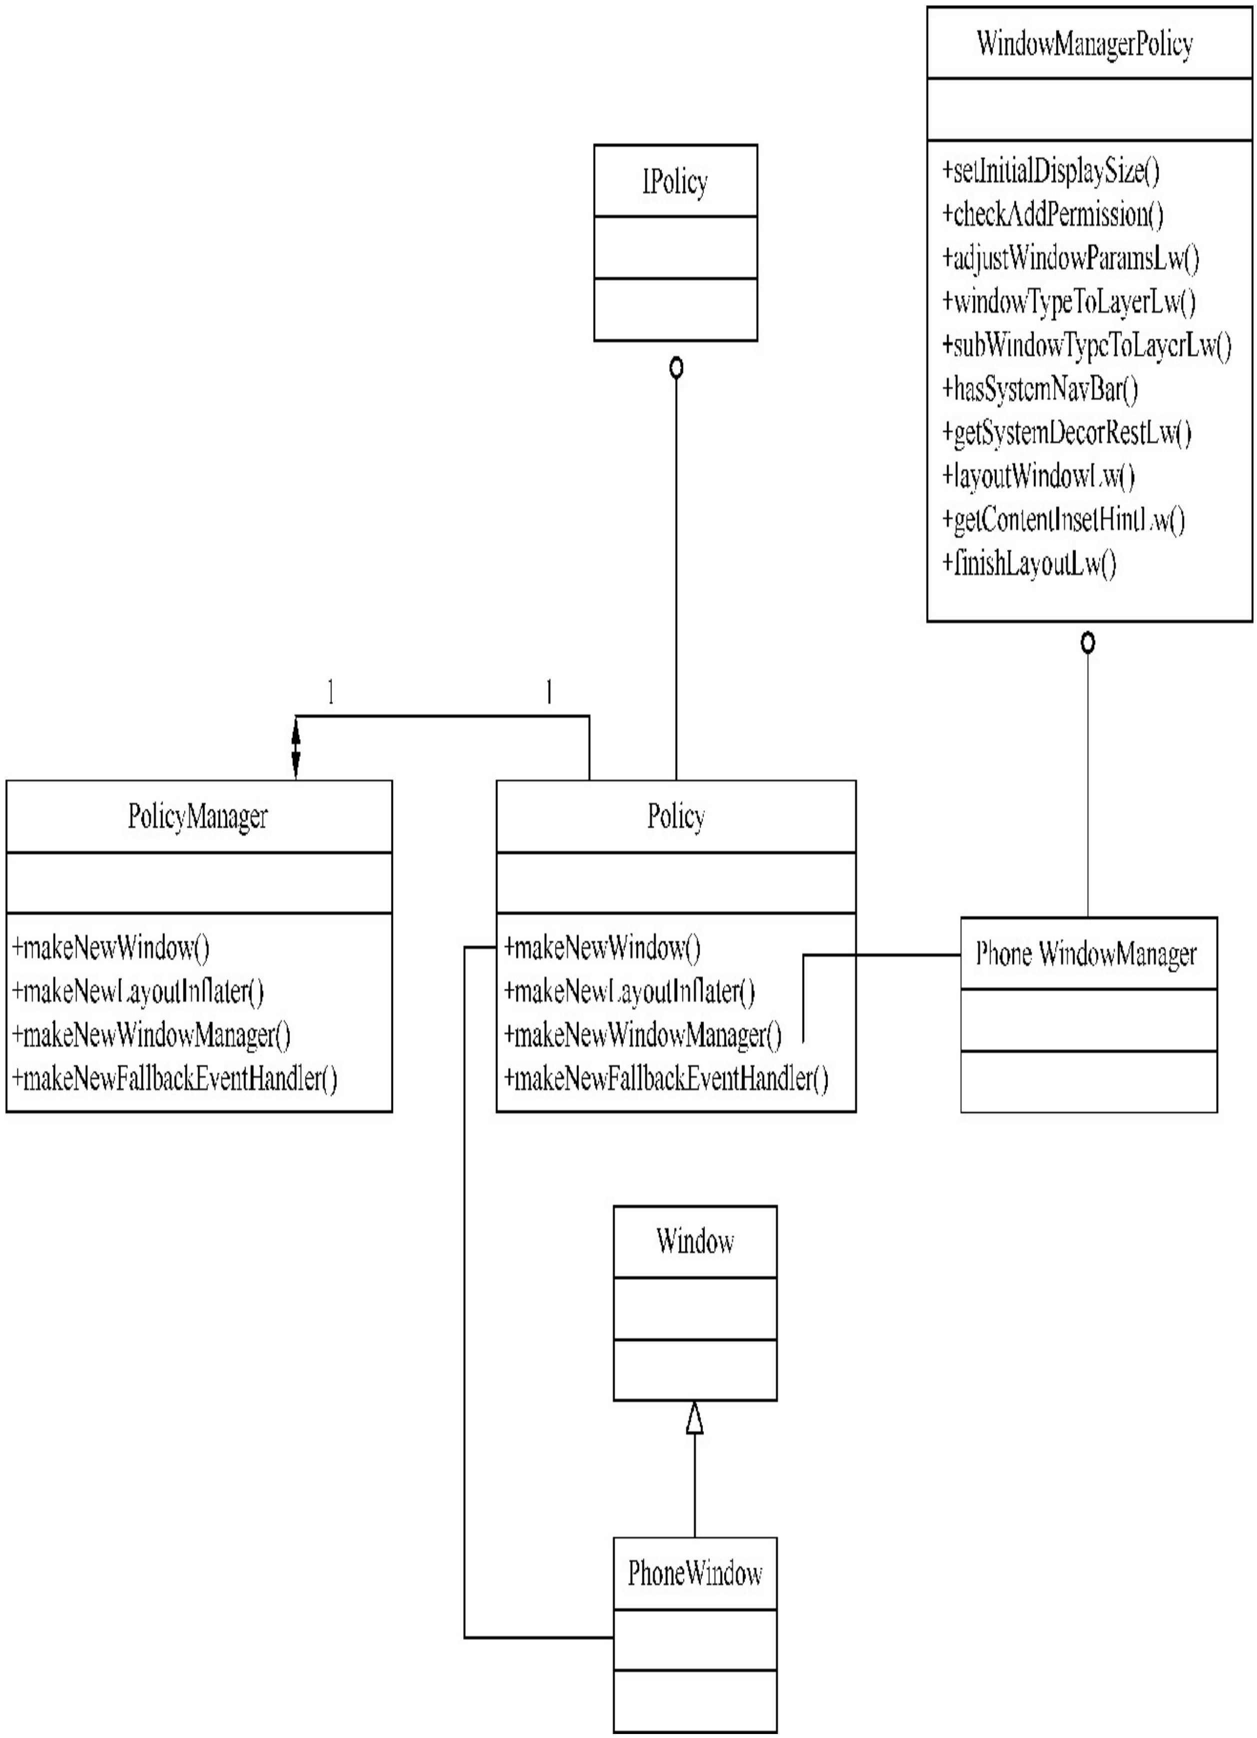

WindowManagerPolicy
+setInitialDisplaySize()
+checkAddPermission()
+adjustWindowParamsLw()
+windowTypeToLayerLw()
+subWindowTypeToLayerLw()
+hasSystemNavBar()
+getSystemDecorRestLw()
+layoutWindowLw()
+getContentInsetHintLw()
+finishLayoutLw()
IPolicy
1
1
PolicyManager
+makeNewWindow()
+makeNewLayoutInflater()
+makeNewWindowManager()
+makeNewFallbackEventHandler()
Policy
+makeNewWindow()
+makeNewLayoutInflater()
+makeNewWindowManager()
+makeNewFallbackEventHandler()
Phone WindowManager
Window
PhoneWindow

▲图10-5　Policy继承关系

WindowManagerPolicy是窗口管理策略的接口类，它定义了一个窗口策略所要遵循的通用规范以及需要提供的相关接口，如getContentInsetHintLw，hasSystemNavBar等。因为系统可能同时支持多种产品类别，我们有必要在运行中指定具体采用的窗口和窗口管理策略，这个工作由Policy.java来完成。这个类可以看作Policy的生产者，它的接口类是IPolicy。不过通常我们并不直接产生一个Policy对象，而是利用PolicyManager所提供的静态接口来产生，如WindowManagerService中的实现：

```
WindowManagerPolicy mPolicy = PolicyManager.makeNewWindowManager(
```

而在PolicyManager.java中：

```
    static {
        // Pull in the actual implementation of the policy at run
        try {
            Class policyClass = Class.forName(POLICY_IMPL_CLASS_N
            sPolicy = (IPolicy)policyClass.newInstance();
        } catch (ClassNotFoundException ex) {
           …
    }
    public static WindowManagerPolicy makeNewWindowManager() {
        return sPolicy.makeNewWindowManager();
    }
    POLICY_IMPL_CLASS_NAME="com.android.internal.policy.impl.Poli
```

因而PolicyManager只是单纯地生成了一个Policy对象，然后通过它的makeNewWindow Manager来进一步产生一个具体的“窗口管理策略”。在Android4.3中，默认的策略如下所示：

```
/*frameworks/base/policy/src/com/android/internal/policy/impl/Pol
    public Window makeNewWindow(Context context) {
        return new PhoneWindow(context);
}

    public WindowManagerPolicy makeNewWindowManager() {
        return new PhoneWindowManager();
}
```

也就是我们前面提到的，默认情况下系统采用的是“Phone”这一

产品的窗口和窗口管理策略。其中“PhoneWindowManager”这个名称也很容易误导人，如果改为“PhoneWindowManagerPolicy”或许更能让人接受。关于Window和WindowManagerPolicy中各接口方法的具体实现，我们接下来会再做详细分析。

10.2.3　窗口属性（LayoutParams）

除了WindowType外，WMS中还牵涉到很多其他的窗口属性。开发者可以通过设置不同的属性来使UI界面显示出各种样式——它们就像窗口用户与WMS间的协议一样，WMS就是为了实现这些用户需求而努力的。另外，了解这些属性的含义也能帮助我们更好地理解WMS的内部原理。

这些属性统一放置在WindowManager.LayoutParams中，接下来我们分析其中几个重要的变量。

1．Type

也就是窗口类型，不再赘述。

2．Flags

窗口的标志，默认值是0。目前Android 4.3系统上支持的flag标志以及含义如表10-5所示。

表10-5　窗口标志释义

Flags	Description
FLAG_ALLOW_LOCK_WHILE_SCREEN_ON	只要此窗口可见，即便屏于开启状态也允许锁屏
FLAG_DIM_BEHIND	在窗口后面的所有东西都暗淡（dimmed）

FLAG_NOT_FOCUSABLE	此窗口不获得输入焦点，着事件将发给该窗口后面他窗口。在设置了此标志时，FLAG_NOT_TOUCH_MO 也会被同时设置
FLAG_NOT_TOUCHABLE	和上面的标志类似，它表窗口不接受任何触摸事件
FLAG_NOT_TOUCH_MODAL	“无模式”的窗口。也就是在该窗口区域外的pointer将传给它后面其他窗口，是由它自己来处理这些事
FLAG_TOUCHABLE_WHEN_WAKING	当设备进入睡眠状态时，此标志可以使你获得第一触摸事件（因为这时候用不知道他们点击的是屏幕哪个位置，所以通常这一是由系统自动处理的）
FLAG_KEEP_SCREEN_ON	只要这个窗口可见，屏幕着
FLAG_LAYOUT_IN_SCREEN	窗口显示时不考虑系统装（比如Status Bar）
FLAG_LAYOUT_NO_LIMITS	允许窗口超过屏幕区域

FLAG_FULLSCREEN	隐藏所有的屏幕装饰窗口 Status Bar。这对于视频播 之类的应用程序是很有用
FLAG_FORCE_NOT_FULLSCREEN	和上面的标志相反
FLAG_SECURE	窗口内容被认为是保密的 而它不会出现在截屏中， 会在不安全的屏幕上显示
FLAG_SCALED	按照用户提供的参数做相 伸缩调整
FLAG_IGNORE_CHEEK_PRESSES	有的时候用户和屏幕会贴 近，如打电话时。这种情 出现的某些事件有可能是 意”的，不应该响应
FLAG_LAYOUT_INSET_DECOR	只能和 FLAG_LAYOUT_IN_SCI 一起使用。当设置了“全 示”布局时，应用窗口部 容仍然可能会被系统装饰 覆盖。如果同时设置了这 志，系统将充分考虑装饰 所占的区域，以防止上述
FLAG_SHOW_WHEN_LOCKED	使窗口能在锁屏窗口之上

FLAG_SHOW_WALLPAPER	让壁纸在这个窗口之后显换句话说，当窗口是透明透明时就可以看到后面的背景（如Launcher）
FLAG_TURN_SCREEN_ON	窗口显示时将屏幕点亮
FLAG_DISMISS_KEYGUARD	设置这个标志可以解除屏锁，只要它不是一个secu lock
FLAG_HARDWARE_ACCELERATED	指明窗口是否需要硬件加当然，设置了这一标志并保证窗口一定会得到硬件（取决于设备配置等一系素）

可以通过以下方法来设置一个窗口标志：

```
Window w = activity.getWindow();
w.setFlags(WindowManager.LayoutParams.FLAG_HARDWARE_ACCELERATED,
            WindowManager.LayoutParams.FLAG_HARDWARE_ACCELERATED)
```

3．systemUiVisibility

从名称可以看出，这个变量表示的是系统UI的可见性。如果读者不清楚哪些元素属于“系统UI”，建议先参考阅读本书应用篇中的介绍。

要特别注意的是，SystemUiVisibility的可选Flags值定义在View类中，而不是WindowManager，具体如表10-6所示。

表10-6　SystemUiVisibility部分标志释义

Flags	

SYSTEM_UI_FLAG_VISIBLE	View视图请求显示
SYSTEM_UI_FLAG_LOW_PROFILE	View请求进入“low Status Bar/Navigati 常游戏、电子书阅 需求
SYSTEM_UI_FLAG_HIDE_NAVIGATION	这个标志用于请求 参见本书应用篇中 标志经常与FLAG_ FLAG_LAYOUT_ 才能使应用程序的
SYSTEM_UI_FLAG_FULLSCREEN	整个View将进入全 WindowManager.L FLAG_FULLSCR 不过和Window提 用 Window.FEATUR 的ActionBar，Sys 它隐藏。根据经验 求，可以采用 SYSTEM_UI_FLA 是长时间的全屏显 最好使用Window
SYSTEM_UI_FLAG_LAYOUT_FULLSCREEN	参见本小节最后的 SYSTEM_UI_FLA
SYSTEM_UI_FLAG_LAYOUT_HIDE_NAVIGATION	和上面标志的意义

SYSTEM_UI_FLAG_LAYOUT_STABLE	系统将尽量保持U

由前面的分析可知，我们只能对一个View（而不是Window）设置它的systemUiVisibility。如果你希望某个Activity中的整棵View树都使用同一个systemUiVisibility，可以在Activity的onCreate中加入类似于如下的代码段（在调用setContentView前）：

```
int newVis = View.SYSTEM_UI_FLAG_LAYOUT_FULLSCREEN
                | View.SYSTEM_UI_FLAG_LAYOUT_HIDE_NAVIGATION
                | View.SYSTEM_UI_FLAG_LAYOUT_STABLE;
getWindow().getDecorView().setSystemUiVisibility(newVis);
```

默认情况下，系统是从StatusBar下面的部分开始给应用程序做UI布局的。而上述这段代码的目的就是使Activity以整个屏幕来布局——最为关键的是，同时还要显示StatusBar。显然FLAG_FULLSCREEN不能符合这个需求（因为它会隐藏系统的装饰部分，包括StatusBar）；而SYSTEM_UI_FLAG_LAYOUT_FULLSCREEN这个标志会保留包括StatusBar在内的系统窗口，同时会让View全屏显示。换句话说，你的View界面布局是从屏幕的（0,0）坐标开始的，但屏幕上方的一小部分内容会被StatusBar所遮盖。

那么，在什么场景下我们需要做这样的处理呢？

举个例子，现在很多定制手机的StatusBar是透明的。如果应用程序按照正常的做法从StatusBar以下的位置开始布局，那么用户透过StatusBar看到的“画面”就是“黑的”；而如果从（0,0）位置开始布局，那么用户就可以透过StatusBar看到应用程序的部分“View”内容了。另外，有的应用程序需要频繁地在“显示系统装饰窗口”和“隐藏系统装饰窗口”间切换，为了让这两种情况下View本身的布局保持不变，也可以使用这一标志。

10.3 窗口的添加过程

10.3.1 系统窗口的添加过程

Android系统中的“窗口”类型虽然很多，但只有两大类是经常使用的：其一是由系统进程管理的，称之为“系统窗口”；其二就是应用程序产生的，用于显示UI界面的“应用窗口”。接下来的两个小节中，我们将分别介绍这两类窗口的添加过程；并通过这两条线索，把其中涉及的各环节知识一一剖析清楚。

本书应用篇的SystemUI章节，读者将看到StatusBar是通过WMS的addView方法最终将自己添加到屏幕上进行显示的。这一步表面上显得平淡无奇，但其内部实现还是比较复杂的。本小节我们就以此为入口点来讲解系统窗口的添加流程：

```
/*frameworks/base/packages/systemui/src/com/android/systemui/stat
 private void addStatusBarWindow() {
      final int height = getStatusBarHeight();/*先获得状态栏的高度。
                                             栏的默认高度，可以关注下
      final WindowManager.LayoutParams lp = new WindowManager.Lay
              ViewGroup.LayoutParams.MATCH_PARENT,//宽度
              height, WindowManager.LayoutParams.TYPE_STATUS_BAR,
              WindowManager.LayoutParams.FLAG_NOT_FOCUSABLE
          |WindowManager.LayoutParams.FLAG_TOUCHABLE_WHEN_WAKING
          |WindowManager.LayoutParams.FLAG_SPLIT_TOUCH,
              PixelFormat.TRANSLUCENT);/*LayoutParams中的各参数我们

        lp.flags |= WindowManager.LayoutParams.FLAG_HARDWARE_ACCE
        lp.gravity = getStatusBarGravity();
        lp.setTitle("StatusBar");
        lp.packageName = mContext.getPackageName();
        makeStatusBarView();/*准备mStatusBarWindow，这个函数会先通过i
                       R.layout.super_status_bar来产生一个View对象，
        mWindowManager.addView(mStatusBarWindow, lp);//将StatusBa
    }
```

上面的代码段是将StatusBar显示到终端屏幕上最关键的部分。函数addStatusBarWindow首先填写描述StatusBar窗口的WindowManager.LayoutParams属性值，包括Width，Height，WindowType，Gravity，Title，PackageName以及各种其他标志。我们已经在前面小节详细讲解过这些属性值的定义，此处不再赘述。

接着程序调用如下语句将自己添加到WMS中：

```
mWindowManager.addView(mStatusBarWindow, lp);
```

也就是说，上面的这些属性值描述的是mStatusBarWindow(StatusBarWindowView)这个对象。StatusBarWindowView类本质上是一个FrameLayout（所以也是一个View组件）。如果大家想更详细地了解StatusBar内部的layout布局，可以参考本书SystemUI章节。我们这里假设mStatusBarWindow已经准备就绪。

变量mWindowManager是一个WindowManager对象，它的定义如下：

```
mWindowManager = (WindowManager)mContext.getSystemService(Context
```

WindowManager（WindowManagerService也是同样的情况）对象的获取与存储虽然并不是很难，但如果方式不当也会影响进程的执行速度。或许也是因为这个，Android各个版本中对此都有不小的改动。目前Android4.3的做法是，将常用的一些服务统一放在SYSTEM_SERVICE_MAP中：

```
    private static final HashMap<String, ServiceFetcher> SYSTEM_S
            new HashMap<String, ServiceFetcher>();
```

这个HashMap的String指的是服务名称，如WINDOW_SERVICE，STORAGE_SERVICE，TELEPHONY_SERVICE等；而ServiceFetcher则提供了真正获取String对应服务的接口，如我们关心的WINDOW_SERVICE：

```
/*frameworks/base/core/java/android/app/ContextImpl.java*/
…
new ServiceFetcher() {
    public Object getService(ContextImpl ctx) {
        Display display = ctx.mDisplay;
        if (display == null) {
            DisplayManager dm = (DisplayManager)ctx.getOuterConte
                                    Context.DISPLAY_SERVICE);
            display = dm.getDisplay(Display.DEFAULT_DISPLAY);
        }
        return new WindowManagerImpl(display);
    }
}
```

由此可知，mContext.getSystemService(Context.WINDOW_SERVICE)返回的是一个Window ManagerImpl对象——注意它是存在于本地进程中的一个对象，并未与远端WMS发生关系。

值得一提的是，WindowManagerImpl继承自WindowManager，那么后者呢？

```
public interface WindowManager extends ViewManager {
     public Display getDefaultDisplay();
     public void removeViewImmediate(View view);
     public boolean isHardwareAccelerated();
     …
}
```

WindowManager是一个接口类，而且从其接口方法的声明中可以看出和WMS并没有直接的关系。可以这么说，WindowManager更像WindowManagerImpl的约束协议，而后者也没有与WMS中提供的服务一一对应。这和我们在ServiceManager看到的情况有一定差异。不过要记住的是，不论形式怎么变，进程间通信仍然是要通过Binder驱动以及ServiceManager进行，因而是“换汤不换药”的做法。

再来看看ViewManager：

```
/*frameworks/base/core/java/android/view/ViewManager.java*/
public interface ViewManager
{
    public void addView(View view, ViewGroup.LayoutParams params)
    public void updateViewLayout(View view, ViewGroup.LayoutParam
    public void removeView(View view);
}
```

ViewManager又对WindowManager提出了另一种约束。总的来说，它们几个的关系如图10-6所示。

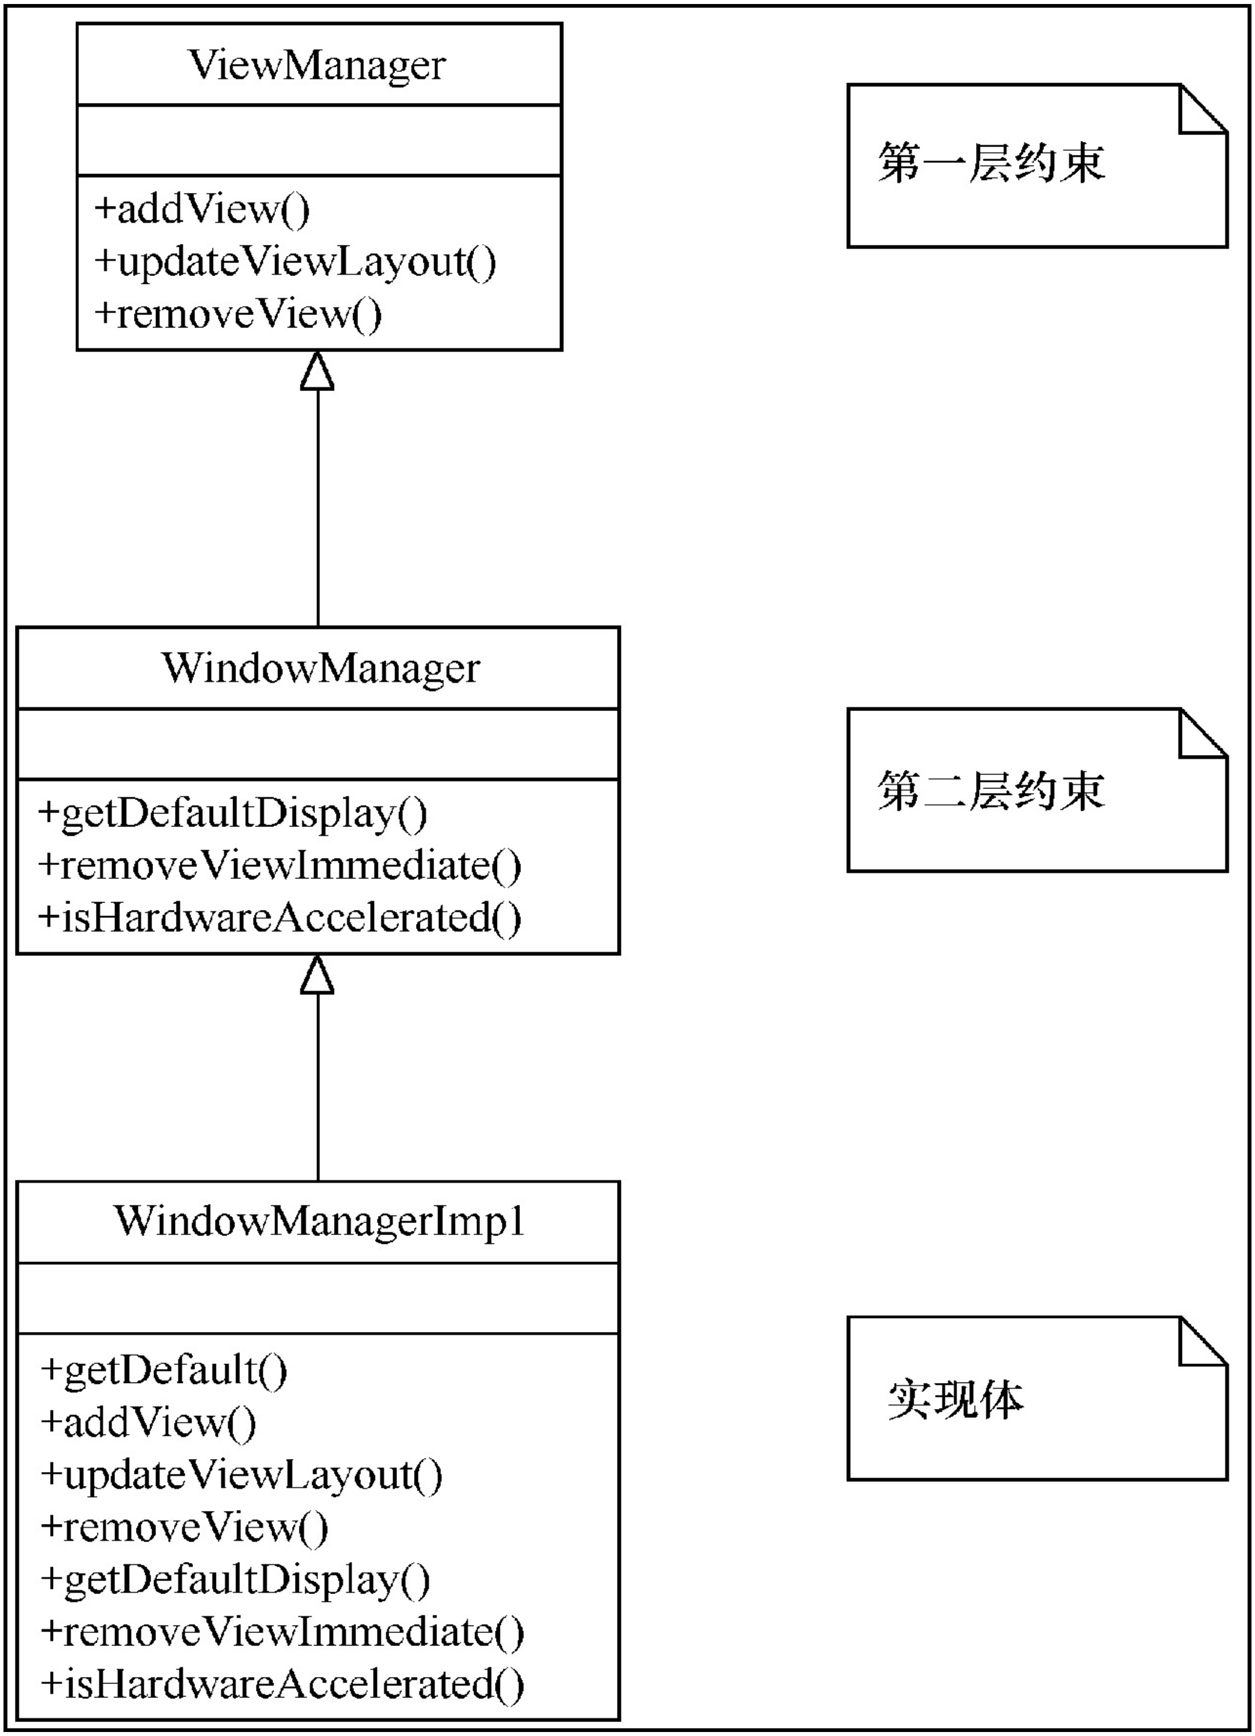
ViewManager
+addView()
+updateViewLayout()
+removeView()
第一层约束
WindowManager
+getDefaultDisplay()
+removeViewImmediate()
+isHardwareAccelerated()
第二层约束
WindowManagerImpl
+getDefault()
+addView()
+updateViewLayout()
+removeView()
+getDefaultDisplay()
+removeViewImmediate()
+isHardwareAccelerated()
实现体

▲图10-6　WindowManager在本地的实现类

我们回过头来看WindowManagerImpl中是如何具体实现addView的。具体如下所示：

```
/*frameworks/base/core/java/android/view/WindowManagerImpl.java*/
public void addView(View view, ViewGroup.LayoutParams params) {
        mGlobal.addView(view, params, mDisplay, mParentWindow);
    }
```

mGlobal是一个全局变量，同时也是单实例。它提供的addView函数接口的实现如下：

```
/*frameworks/base/core/java/android/view/WindowManagerGlobal.java
public void addView(View view, ViewGroup.LayoutParams params, Dis
        ViewRootImpl root;//注意WindowManagerImpl和ViewRoot在同一进
        View panelParentView = null;
        synchronized (mLock) {…//锁保护
            int index = findViewLocked(view, false);//以前是否已经添
            if (index >= 0) {//已经添加过，禁止重复操作
                throw new IllegalStateException("View " + view
                        + " has already been added to the window
            }
        …
        root = new ViewRootImpl(view.getContext(), display);
            view.setLayoutParams(wparams);//为这个View对象设置属性
            if (mViews == null) {//此进程是第一次添加View
               ..//源码见后面的Case1.
            } else {//之前已经添加过View
               ..//源码见后面的Case2.
            }
            index--;
            mViews[index] = view;
            mRoots[index] = root;
            mParams[index] = wparams;
        }
        try {
            root.setView(view, wparams, panelParentView);//真正的"
        } catch (RuntimeException e) {
            ..//异常处理
        }
    }
```

在这个场景中，函数addView的各参数分别是：view对应

mStatusBarWindow，params对应lp，display是默认的显示屏，parentWindow为null。

上述代码段中首先调用findViewLocked来查找是不是已经添加过这个view对象。查找过程很简单，即逐个对比mViews[]数组中的元素是否和view一致即可——如果结果是肯定的，那就没必要重复添加了，直接抛出异常；否则必须为此view对象生成一个对应的ViewRootImpl。这里特别说明一下，WindowManagerGlobal中有3个相关联的成员数组变量。如下：

```
private View[] mViews;
private ViewRootImpl[] mRoots;
private WindowManager.LayoutParams[] mParams;
```

这3个数组的大小都是逐步扩大的，而且保持一致。换句话说，同一个index值在3个数组中描述的是同一个对象。我们在后续的ViewRoot章节还会详细论述。

接下来分为两种情况。

Case1. 如果是第一次添加View

此时mViews == null，处理如下：

```
index = 1;
mViews = new View[1];
mRoots = new ViewRootImpl[1];
mParams = new WindowManager.LayoutParams[1];
```

Case2. 之前已经至少添加过一个View，处理如下：

```
index = mViews.length + 1;
Object[] old = mViews;
mViews = new View[index];
System.arraycopy(old, 0, mViews, 0, index-1);
old = mRoots;
mRoots = new ViewRootImpl[index];
System.arraycopy(old, 0, mRoots, 0, index-1);
old = mParams;
mParams = new WindowManager.LayoutParams[index];
System.arraycopy(old, 0, mParams, 0, index-1);
```

假设mViews为空，说明这是它添加的第一个View对象，因而需要分别为mViews和mRoots分配该对象的存储空间。因为mViews中的View数量没有办法预先估计，为了节省内存，程序在每添加一个View时都只申请刚刚好的空间大小（即new View[index]），然后将之前的数据复制到数组的相应位置。其他两个数组mRoots和mParams也需要做同样的处理。最后，我们把view，root和wparams这些新增对象分别添加到上述三个数组中。

函数结尾处调用了ViewRootImpl.setView()——到目前为止，所有的操作都还是在本地进程中执行的。那么添加一个ViewRoot，需不需要让WMS知道呢？

答案是肯定的。为了保持连贯性，我们来看看ViewRootImpl::setView的实现重点：

```
/*frameworks/base/core/java/android/view/ViewRootImpl.java*/
    public void setView(View view, WindowManager.LayoutParams att
        synchronized (this) {
            if (mView == null) {
                mView = view;//一个ViewRootImpl对应一棵ViewTree，因而
                …
                requestLayout();//发起layout请求
                …
                try {…
                   res = mWindowSession.addToDisplay(mWindow, mSe
                          getHostVisibility(), mDisplay.getDispla
                          mAttachInfo.mContentInsets, mInputChann
                } catch (RemoteException e) {
                   …//出错处理
                } finally {
                   //收尾工作
                }
…
```

我们知道，WMS才是窗口管理系统。因而当应用程序新增了一个顶层View（ViewTree的根）时，是肯定要通知WMS的。在将View树（在WMS看来，它是一个“Window”，由WindowState来管理）注册到WMS前，需要注意什么呢？没错，必须先执行第一次layout，也就是调用requestLayout——WMS除了窗口管理外，还负责各种事件的派发，所以在向WMS“注册”前应用程序要确保这棵View树已经做好了接收事件的准备。

ViewRoot起到了中介的作用。作为整棵View树的“管理者”，它同时也担负着与WMS进行IPC通信的重任。具体而言，就是通过IWindowSession建立起双方的桥梁，如图10-7所示。

▲图10-7 ViewRoot与WMS的通信

这些知识点在前面的WMS、AMS和Activity的关系中已经讲解过了。

在ViewRootImpl的构造函数中，会通过getWindowSession来打开一个与WMS的可用连接。这个函数的逻辑很简单，读者可以自行阅读。

得到IWindowSession后，setView便利用它来发起一个服务请求。即：

```
 res = mWindowSession.addToDisplay(mWindow, mSeq, mWindowAttr
```

在IWindowSession服务端的实现中（Session.java），函数addToDisplay（早期版本中，这个接口叫作add。大家可以从名称的变化中看出Android系统正在增加对多显示屏的支持）又直接调用了WMS中的addWindow：

```
/*frameworks/base/services/java/com/android/server/wm/Session.jav
public int addToDisplay(IWindow window, int seq, WindowManager.La
            int viewVisibility, int displayId, Rect outContentIns
            InputChannel out InputChannel) {
       return mService.addWindow(this, window, seq, attrs, viewVi
                      outContentInsets, outInputChannel);
    }
```

仔细分析一下ViewRoot提供给IWindowSession的参数：第二个参数是IWindow，即WMS回调ViewRoot时要用到的。第三个参数是一个int数值，有点类似于前一章节SurfaceFlinger中的sequence，是用于WMS与

ViewRoot间状态同步的。在WMS服务端，这个状态同步值（sequence）记录在WindowState::mSeq中。当updateStatusBarVisibilityLocked时，sequence值有可能会改变，并通过IWindow::dispatchSystemUiVisibilityChanged这个callback函数通知ViewRoot进行更新。第四个参数是关于属性的，后面小节有详细介绍。第五个参数是View的可见性等。

聪明的读者一定发现了其中并没有View对象或者“View树”相关的变量。为什么呢？

因为WMS并不关心View树所表达的具体UI内容，它只要知道各应用进程显示界面的大小、“层级值”（这些信息已经包含在WindowManager.LayoutParams中）即可。

来看看WMS中的addWindow实现：

```
/*frameworks/base/services/java/com/android/server/wm/WindowManag
     public int addWindow(Session session, IWindow client, int se
     Params attrs, int viewVisibility, int displayId, Rect outCon
                     outInputChannel) {
        int[] appOp = new int[1];
        int res = mPolicy.checkAddPermission(attrs, appOp);/*Step
        …
        WindowState attachedWindow = null;//适用于Sub Window的情况
        WindowState win = null;//WindowState用于记录一个Window
        long origId;
        final int type = attrs.type;//窗口类型
        synchronized(mWindowMap) {
            …
            if (mWindowMap.containsKey(client.asBinder())) {/*Ste
               Slog.w(TAG, "Window " + client + " is already adde
               return WindowManagerGlobal.ADD_DUPLICATE_ADD;
            }
            if (type >= FIRST_SUB_WINDOW && type <= LAST_SUB_WIND
               attachedWindow = windowForClientLocked(null, attrs
               …
            }
            boolean addToken = false;//用来标识后面是否有添加Token的操
            WindowToken token = mTokenMap.get(attrs.token);
            if (token == null) {…
            } else if (type >= FIRST_APPLICATION_WINDOW && type
                                         <= LAST_APPLICATION_WIND
            } else if (type == TYPE_INPUT_METHOD) {…
            } else if (type == TYPE_WALLPAPER) {…
```

```
        } else if (type == TYPE_DREAM) {…
        }/*Step4. 根据不同窗口类型，检查有效性*/

        win = new WindowState(this, session, client, token, a
                        seq, attrs, viewVisibility, displayC
        if (win.mDeathRecipient == null){…/*Step6. 客户端已经死
            return WindowManagerGlobal.ADD_APP_EXITING;
        }

        mPolicy.adjustWindowParamsLw(win.mAttrs);/*Step7. 调整
        win.setShowToOwnerOnlyLocked(mPolicy.checkShowToOwner
        res = mPolicy.prepareAddWindowLw(win, attrs);
        …
        res = WindowManagerGlobal.ADD_OKAY;
        origId = Binder.clearCallingIdentity();
        if (addToken) {/*Step8. 前面步骤中新增了Token元素*/
            mTokenMap.put(attrs.token, token);//把它添加进mToke
        }
        …
        mWindowMap.put(client.asBinder(), win);/*注意和mTokenM
        …
        boolean imMayMove = true;
        /*Step9. 接下来会将所有Window按顺序进行排列*/
        if (type == TYPE_INPUT_METHOD) {…
        } else if (type == TYPE_INPUT_METHOD_DIALOG) {…
        } else {
          addWindowToListInOrderLocked(win, true);
          …
        }
        …
        if (displayContent.isDefaultDisplay) {
          mPolicy.getContentInsetHintLw(attrs, outContentInse
        } else {
          outContentInsets.setEmpty();
        }
        assignLayersLocked(displayContent.getWindowList());/*
        …
    return res;
}
```

Step1@addWindow。首先对用户的窗口请求进行权限检查，如果窗口的类型是：

```
type < FIRST_SYSTEM_WINDOW|| type > LAST_SYSTEM_WINDOW
```

就直接返回ADD_OKAY，因为任何人都有权限添加非系统窗口；否则

说明添加的是系统窗口，需要进一步细化——比如TYPE_TOAST虽然是系统窗口，但是应用程序也有权限来创建。而TYPE_PHONE，TYPE_SYSTEM_ERROR等窗口类型就需要相应的权限许可才能使用，即android.Manifest.permission.SYSTEM_ALERT_WINDOW。

Step2@addWindow。变量mWindowMap是一个<IBinder，WindowState>类型的HashMap，前面的IBinder代表IWindow。所以mWindowMap是WMS中与此IWindow相对应的WindowState的映射。另外，下面还会出现<IBinder，WindowToken>类型的mTokenMap，读者应注意区分。一个IWindow只允许添加唯一的窗口，否则函数会直接报错返回。当然，一个应用进程中是可以持有多个ViewRoot对象的——意味着它所管理的ViewTree理论上并没有数量上的限制。

除了避免重复添加外，程序还会对用户的窗口添加请求进行各种其他的前期处理，包括系统初始化条件判断等。如果一切顺利，才能继续往下执行。

Step3@addWindow。如果要添加的窗口类型为“子窗口”，还要先找出它的“父窗口”；而且要特别注意“父窗口”本身不能是其他窗口的“子窗口”，否则添加会失败。具体的函数实现是windowForClientLocked。

Step4@addWindow。这里有几个相似的Token变量很容易混淆，我们统一进行讲解。

- token

  类型为WindowToken。

- attrs.token

  类型为IBinder。它代表了这个窗口的“主人”。AMS为每一个Activity都分别创建了一个ActivityRecord对象，其本质就是一个IBinder。在启动Activity时，这个token会被自动赋值，因而开发人员可以不用特别关注。

- addToken

布尔类型，用于指示后续操作中有没有新的Token被添加。

我们以图10-8来理顺各Token的关系。

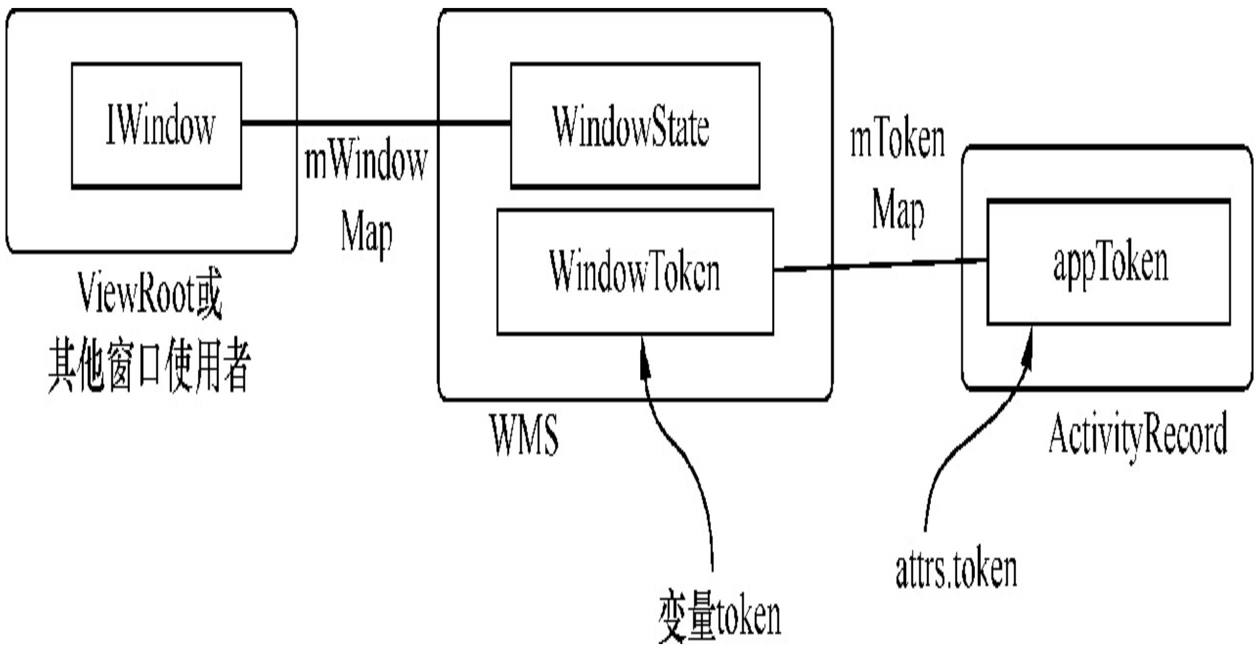

▲图10-8 各token的关系图

所以这里的有效性检查逻辑是:

- 如果attrs.token在mTokenMap中找不到对应的WindowToken，说明它在AMS中没有记录。此时分为两种情况:

（1）假如是以下几种窗口类型，则必须在AMS中“有案可询”：

```
 [FIRST_APPLICATION_WINDOW，LAST_APPLICATION_WINDOW]
TYPE_INPUT_METHOD
TYPE_WALLPAPER
TYPE_DREAM
```

也就是说，这些类型的窗口必须事先已经在mTokenMap中添加了对应关系——这一步是由AMS为它们自动完成的。如果此时找不到，很可能说明某些步骤出现了问题，所以程序会报错返回。

（2）除上述所列之外的窗口类型，允许在AMS中没有“备案”。接着程序会主动为这个窗口生成一个WindowToken，并置addToken为

true。

- 如果在mTokenMap可以找到对应的WindowToken，根据前一种情况的分析，只有上面所列举的那几种窗口类型（TYPE_INPUT_METHOD等）才有可能在mTokenMap中事先添加了对应关系。此时还需做进一步检查：比如在Application Window的情况下，还要求token.appWindow Token也不能为空。除此之外，ViewRoot所指示的windowType(attrs.type)必须和AMS中当时登记的类型（token.windowType）完全一致，否则就会报ADD_BAD_APP_TOKEN的错误。

Step5@addWindow。如果一切顺利，WMS会为这个窗口新增一个WindowState：

```
        win = new WindowState(this, session, client, token,
              attachedWindow, appOp[0], seq, attrs, viewVisibilit
```

WindowState构造函数中的几个参数：this代表WMS自身；session是WMS提供给窗口使用者的IwindowSession；client则是Iwindow，即窗口使用者提供给WMS的访问通道；token是WindowToken对象；attachedWindow代表父窗口（如果存在的话）等。这个函数在前面小节已经讲解过，其中一个重点就是为窗口分配基础层级（mBaseLayer）。

Step6@addWindow。如果客户端已经死亡，那么就不需要继续往下执行了。这种情况是有可能发生的，如应用进程异常Crash。

Step7@addWindow。调用Policy进行窗口参数的调整，此时Policy会对某些情况进行约束。函数adjustWindowParamsLw很简单，读者可以看看。另一个prepareAddWindowLw还是进行必要的检查工作，如某些类型的窗口在系统中只允许同时有一个存在等。

Step8@addWindow。如果前面几个步骤中新增了Token对象，那么此时我们需要把它添加到全局HashMap中，即mTokenMap。

Step9@addWindow。因为我们新增一个Window，很可能会影响之前已经排列好的WindowList，所以通过相应的“添加函数”（如addWindowToListInOrderLocked）将此新窗口按顺序添加到WindowList中。另外，如果用户指定了FLAG_SHOW_WALLPAPER（比如有的应用程序

在属性中指明需要以壁纸为背景；或者有的应用程序部分UI区域是透明的，假如没有壁纸做底层背景的话，这块区域就会是黑的）或者本身就是壁纸类型的窗口，还要调用adjustWallpaper WindowsLocked进行壁纸调整。稍后我们会详细分析对窗口进行调整的函数addWindowToListIn OrderLocked。

Step10@addWindow。函数getContentInsetHintLw用于计算窗口的ContentInset区域，我们将在窗口大小这一小节中进行分析。

Step11@addWindow。函数assignLayersLocked在前面讲解Window层级时已经分析过，它负责给上一步已经排好序的WindowList中的各窗口一一分配最终的层级值。

先来看看addWindowToListInOrderLocked的实现。从名称就可以看出，它需要将系统中当前所有的窗口进行排列。那么，按照什么顺序呢？

```
private void addWindowToListInOrderLocked(WindowState win, bool
    final IWindow client = win.mClient;//WindowState中包含了IWin
    final WindowToken token = win.mToken;//同时还有WindowToken
    final DisplayContent displayContent = win.mDisplayContent;
    final WindowList windows = win.getWindowList();//windows记
    final int N = windows.size();//当前所有窗口的数量
    final WindowState attached = win.mAttachedWindow;//父窗口(如
    int i;//用于循环计数
    WindowList tokenWindowList = getTokenWindowsOnDisplay(toke
    if (attached == null) { //没有父窗口的情况
        int tokenWindowsPos = 0;
        int windowListPos = tokenWindowList.size();
        if (token.appWindowToken != null) {…
        } else { // appWindowToken为null的情况，符合我们的场景
            final int myLayer = win.<strong>mBaseLayer</strong
            for (i=N-1; i>=0; i--) {//寻找合适的位置
                if (windows.get(i).mBaseLayer &lt;= myLayer) {
                    break;//找到了
                }
            }
            i++;
            windows.<strong>add</strong>(i, win);//添加到List中
            mWindowsChanged = true;
        }
        if (addToToken) {
            token.windows.add(tokenWindowsPos, win);
```

```
            }
        } else {…//attached不为空的情况略
     }

        if (win.mAppToken != null && addToToken) {
            win.mAppToken.allAppWindows.add(win);
        }
    }
```

这个函数很长，如果直接看代码相信不少人都会觉得“云里雾里”。因此我们按照本小节的场景（添加StatusBar窗口）先将它拆分成若干个分支，再逐一解析。

- attached==null

最外围的分支是以attached是否为空来界定的。换句话说，是不是子窗口类型。因为本小节讲解的Status Bar是系统窗口，所以我们侧重于attached为空的情况。

- token.appWindowToken != null

紧接着判断appWindowToken是否为空，即当前窗口是不是Activity相关的。因为SystemUI实际上是由Service构成的，所以没有appWindowToken。

根据这个场景，appWindowToken不为null，所以它的位置受到mBaseLayer的影响。这个变量对于Status Bar类型的窗口，计算方法如下：

```
mBaseLayer = mPolicy.windowTypeToLayerLw(a.type)
                * WindowManagerService.TYPE_LAYER_MULTIPLIER
                + WindowManagerService.TYPE_LAYER_OFFSET;
```

其中windowTypeToLayerLw()返回值为15，TYPE_LAYER_MULTIPLIER为10000，TYPE_LAYER_OFFSET是1000——所以mBaseLayer为151000。按照这个值，我们来依次查找windows中所有的基础层级，顺序是数组元素由大至小——这样一旦myLayer大于windows中某个窗口的mBaseLayer值，那么它一定会大于其下面所有窗口的mBaseLayer。所以它的插入位置就是i++（因为它比第i个元素大）。当然，这并不是这个窗口的最终layer值（最终层级由assignLayersLocked来分配）。从中也可以看

出，同一类型窗口的优先级，后创建的优先级高。

这样大家就系统地学习了添加System Window（以Status Bar为例）到WMS中的流程。接下来的小节将在此基础上，对比分析普通应用程序窗口的添加过程。

10.3.2　Activity窗口的添加过程

对于WMS来说，它并不会特别区分窗口的使用者是谁。因而理论上不管是Activity窗口或者系统窗口，在WMS中基本都是一视同仁，只不过层级和权限会有所差异。

当用户启动一个Activity时（比如通过startActivity），AMS首先判断该Activity所属应用程序进程是否已经在运行：如果是就向这个进程发送启动指定Activity的命令；否则先创建该应用进程，运行ActivityThread主线程，然后处理启动Activity的操作。这部分知识在ActivityManagerService章节已经有过详细介绍，不清楚的读者可以回头复习下。

和其他三大组件不同，Activity与生俱来拥有显示UI界面的“基因”，并且它需要WMS的支持才能正常工作。当然，这并不意味着Service或者Broadcast就完全无法显示图形界面——比如前面小节讲解的Status Bar的主体就是一个Service。只不过借助于Activity提供的各种机制，可以为创建和管理UI界面带来诸多便利，这对于开发人员来说“何乐而不为”呢？

当AMS发现一个Activity即将启动时，它需要将相关信息“告知”WMS：

```
/*frameworks/base/services/java/com/android/server/am/ActivitySta
private final void startActivityLocked(…)
{…
     mService.mWindowManager.addAppToken(addPos, r.appToken, r.ta
     screenOrientation,r.fullscreen,
                      (r.info.flags & ActivityInfo.FLAG_SHOW_ON_L
```

WMS会把ActivityRecord记录到我们前面addWindow中看到的HashMap<IBinder, WindowToken>mTokenMap中。根据之前的分析可知，如果没有这一步，Activity应用程序调用addWindow就会失败。

那么Activity应用进程在什么时候会调用addView，进而由WMS来处理addWindow呢？

Activity从启动到最终在屏幕上显示出来，分别要经历onCreate->onStart->onResume三个状态迁移。其中onResume是当界面即将可见时才会调用的，紧接着ActivityThread就会通过WindowManagerImpl来把应用程序窗口添加到系统中。具体代码如下：

```
/*frameworks/base/core/java/android/app/ActivityThread.java*/
final void handleResumeActivity(IBinder token, boolean clearHide,
     ActivityClientRecord r = performResumeActivity(token, clearH
                                             Activity的onResume被最终调
     …
     View decor = r.window.getDecorView();/*DecorView是Activity整
                                              可以参见下一章的分析*/
     decor.setVisibility(View.INVISIBLE);//可见性
     ViewManager wm = a.getWindowManager();//得到的实际上是WindowMa
     WindowManager.LayoutParams l = r.window.getAttributes();//获
     a.mDecor = decor;
     l.type = WindowManager.LayoutParams.TYPE_BASE_APPLICATION;//
     l.softInputMode |= forwardBit;
     if (a.mVisibleFromClient) {
         a.mWindowAdded = true;
         wm.addView(decor, l);//将窗口添加到WMS中
     }
     …
```

值得一提的是，函数performResumeActivity将最终调用Activity的onResume，不过中间还需要经过很多处理过程。如果这个Activity是可见的，那么就需要把它的UI窗口添加到WMS中。一个Activity对应的View树最外围是DecorView，可以由Window.getDecorView()获取。换句话说，开发人员通常在onCreate()中利用setContentView()所设置的“Content”其实只是DecorView中的“内容”部分，而不包括标题栏等“Decor”。这些知识在下一章节会有详细描述，建议读者穿插阅读。

对于一般的应用程序，其窗口类型（Window Type）是TYPE_BASE_APPLICATION，值为1。这也是“层级值”最低的一种窗口类型。WindowManagerImpl对象（即变量wm）则是通过Activity.getWindowManager取得的。

最后我们通过WindowManagerImpl.addView来把DecorView添加到系

统中，这将导致WMS中的addWindow被调用——中间流程和我们在系统窗口添加小节的分析是完全一样的，这里不再赘述。

那么，WMS添加应用窗口和系统窗口相比有何差异呢？

可以说WindowManagerService.addWindow处理这两种类型的窗口时在主体架构上没有任何区别，一般WMS都会为它们生成一个WindowState来管理窗口。不过紧接着将应用窗口添加到全局窗口列表中的处理流程就有所不同了（即前一小节Step9后的步骤）：

```
private void addWindowToListInOrderLocked(WindowState win, boolea
       final IWindow client = win.mClient;//WindowState中包含了IWir
       final WindowToken token = win.mToken;//同时还有WindowToken
       final DisplayContent displayContent = win.mDisplayContent;
       final WindowList windows = win.getWindowList();//windows是
       final int N = windows.size();//当前所有窗口数量
       final WindowState attached = win.mAttachedWindow;//父窗口(如
       int i;//用于循环计数
       WindowList tokenWindowList = getTokenWindowsOnDisplay(toke
          //上面这部分内容和前一小节是完全一样的，不再赘述
       if (attached == null) { //没有父窗口的情况
           int tokenWindowsPos = 0;
           int windowListPos = tokenWindowList.size();//该应用程序名
           if (token.appWindowToken != null) {//应用程序的窗口符合这一
               int index = windowListPos - 1;
               if (index >= 0) {//第一种情况. 该应用程序已包含最少一个窗
                   if (win.mAttrs.type == TYPE_BASE_APPLICATION)
                      WindowState lowestWindow = tokenWindowList.
                      placeWindowBefore(lowestWindow, win);
                      tokenWindowsPos = indexOfWinInWindowList(lo
                   } else {
                       …
                   }
               } else {//第二种情况. 应用程序还没有其他窗口存在
                   …//详细源码抽取到后面进行详细解释
               }
           } else { // appWindowToken为null的情况
              …
           }
           …
       } else {… //attached不为空的情况略
       }
    …
   }
```

函数最前面的一部分内容和系统窗口添加过程中的情况完全一致，此时不再赘述。上述代码段的剩余内容我们也分为若干Case进行解析。

应用程序窗口主要分为两种情况：

- 此应用程序已经拥有至少一个窗口；
- 此应用程序还没有其他窗口存在。

一个应用程序名下的所有窗口，都可以通过token.windows来获得。所以当tokenWindows Pos>=1时，说明应用程序窗口列表的大小不为0，属于第一种情况。

默认情况下Activity中添加的窗口类型是TYPE_BASE_APPLICATION，等级是最低的，因而我们只需把它放置在此应用程序窗口队列中的最底端就可以，即调用placeWindowBefore（lowestWindow，win）。

假如应用程序当前还没有其他窗口存在，情况会复杂一些。我们特别把这部分代码抽取出来，具体如下所示：

```
final int NA = mAnimatingAppTokens.size();
WindowState pos = null;
for (i=NA-1; i>=0; i--) {//Step1.在所有AppWindowTo
    AppWindowToken t = mAnimatingAppTokens.get(i)
    if (t == token) {
        i--;
        break;//找到目标，跳出循环
    }
    tokenWindowList = getTokenWindowsOnDisplay(t,
    if (!t.sendingToBottom && tokenWindowList.siz

        pos = tokenWindowList.get(0);//以此为参考
    }
}
if (pos != null) {//Step2. 在AppWindowToken中找到参
    WindowToken atoken = mTokenMap.get(pos.mClien
    if (atoken != null) {
        tokenWindowList =getTokenWindowsOnDisplay
                                    win.mDisplayContent);
        final int NC = tokenWindowList.size();
        if (NC > 0) {
            WindowState bottom = tokenWindowList.
            if (bottom.mSubLayer < 0) {
```

```
                        pos = bottom;
                    }
                }
            }
            placeWindowBefore(pos, win);//放置在参考物下面
        } else {//Step3 在AppWindowToken中没有找到参考位置
            while (i >= 0) {// 继续向下查找，直到第一个有窗口的
                AppWindowToken t = mAnimatingAppTokens.ge
                tokenWindowList = getTokenWindowsOnDispla
                final int NW = tokenWindowList.size();
                if (NW > 0) {
                    pos = tokenWindowList.get(NW-1);
                    break;
                }
                i--;
            }
            if (pos != null) {//Step3.1第二个循环找到了参考值
                WindowToken atoken = mTokenMap.get(pos.mC
                if (atoken != null) {
                    final int NC = atoken.windows.size();
                    if (NC > 0) {
                        WindowState top = atoken.windows.
                        if (top.mSubLayer >= 0) {
                            pos = top;
                        }
                    }
                }
                placeWindowAfter(pos, win);
            } else {//Step3.2第二个循环后仍然没有找到参考值
                final int myLayer = win.mBaseLayer;//通过B
                for (i=0; i<N; i++) {
                    WindowState w = windows.get(i);
                    if (w.mBaseLayer > myLayer) {
                        break;
                    }
                }
                windows.add(i, win);//最终找到的合适的位置，将
                mWindowsChanged = true;
            }
        }
    }
```

Step1. WindowManagerService不但有mTokenMap这一<IBinder,WindowToken>类型的HashMap，而且还单独将其中AppWindowToken部分数据存储到mAppTokens中。如下：

```
final ArrayList<AppWindowToken> mAppTokens = new ArrayList<AppWin
```

另外，还有一个与mAppTokens非常类似的列表，即上面代码段中的mAnimatingAppTokens。如果当前没有animations在进行，那么它们是完全相同的。从源码实现上来看，函数handleAnimatingStoppedAndTransitionLocked会先清除mAnimatingAppTokens，然后把mAppTokens的所有元素加载进去。

接下来程序逆序查找mAnimatingAppTokens中各个AppWindowToken元素。一旦t==token就跳出循环，而且i自减1；如果当前元素与token不匹配，且!t.sendingToBottom &&tokenWindow List.size()> 0，那么可以用pos记录下该AppWindowToken管理所有windows的第一个，即tokenWindowList.get(0)。这是什么意思呢？

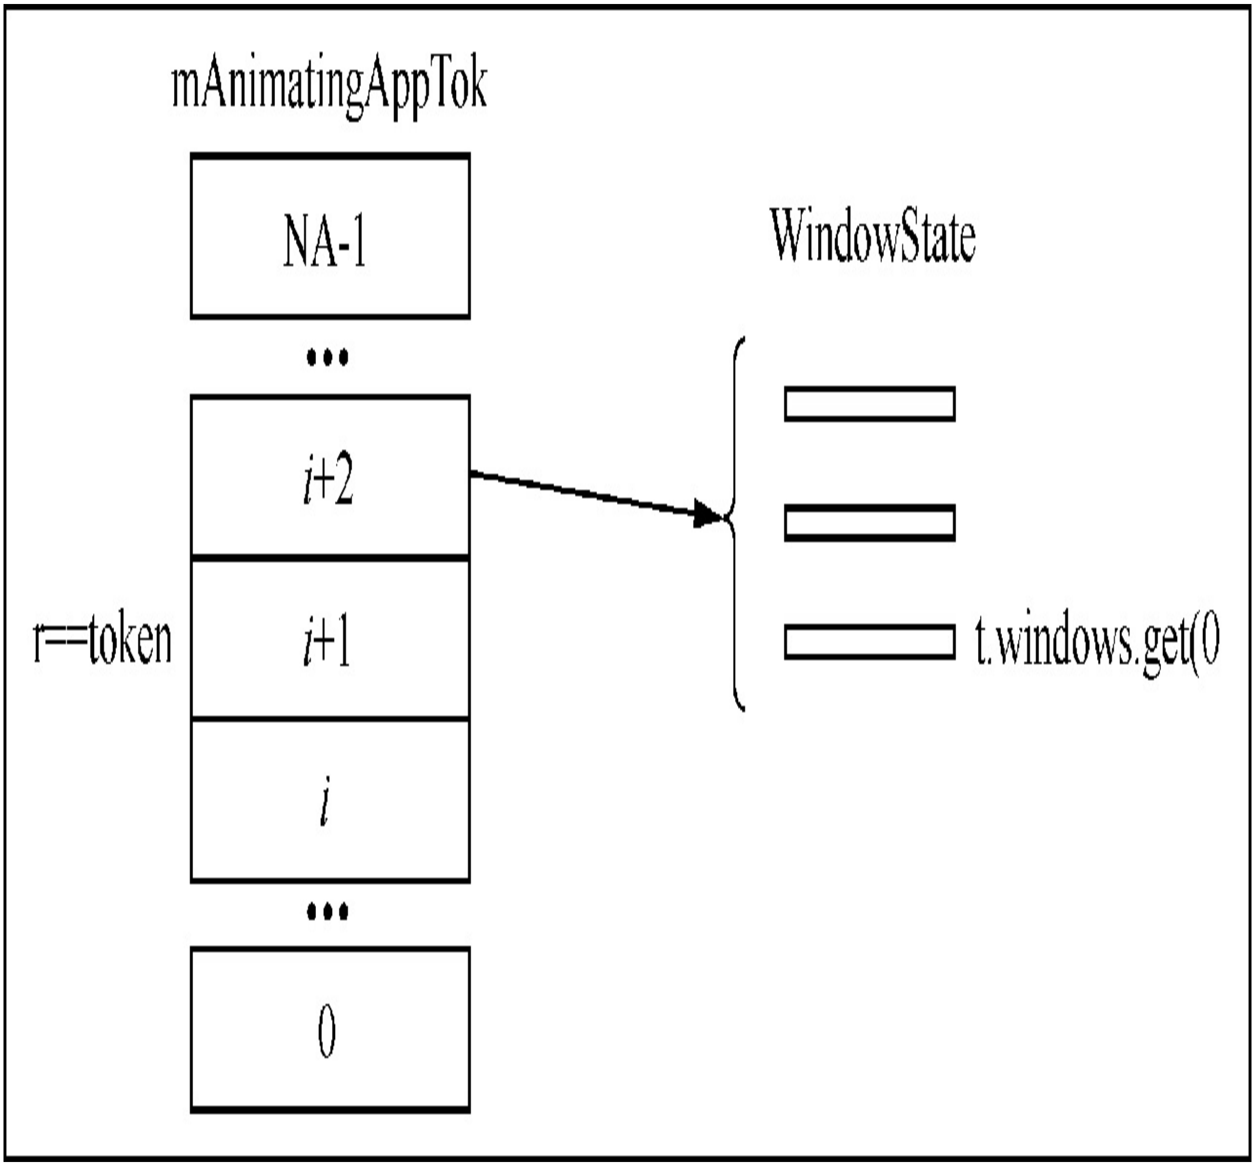

▲图10-9　Step1的查找示意图

图10-9描述了Step1中的一个查找范例。当查找到第i+2个AppWindowToken时，因为t!=token，此时这个token对应的windows不为空，而且这些window不会被移动到底部（sendingToBottom 将在moveAppTokensToBottom中被置为true），所以我们用pos来记录tokenWindowList.get(0)，作为后续的参考。当查找到第i+1时，刚好t==token，所以会跳出循环，而且将i自减1（即i--），所以i的最终值与t所在位置相差1。

Step2. 假如pos!=null，说明我们在前一步骤中成功找到了窗口插

入位置的参考值，即pos。接下来先从mTokenMap中找到pos这个窗口对应的WindowToken：

```
WindowToken atoken = mTokenMap.get(pos.mClient.asBinder());
```

然后判断参考窗口的WindowState.mSubLayer是否小于0，如果是，则pos=bottom。最后，将需要添加的窗口直接放置到参考窗口的下面，即placeWindowBefore(pos,win)。

Step3.如果pos==null，说明前面Step1中没有找到参考位置。原因有很多，如这个token上面的元素没有窗口，或者它们的sendingToBottom为true等。此时就需要“退而求其次”，继续查找mAnimatingAppTokens剩下的元素中第一个带有窗口的那个token。当然，前提必须是i>=0——因为假如Step1中的循环已经遍历了整个列表，那么此时这个循环就不会被执行了。

Step3.1假如Step3中的循环结束后pos!=null，那我们就以这个pos为参考值，并且是将位置放在pos这个窗口所属WindowToken管理的所有windows的最上面。

Step3.2假如Step3中的循环结束后pos仍然为空，那么就以此窗口的BaseLayer为参考标准。具体来说，就是在所有窗口（windows）中查找合适的位置进行插入。

10.3.3　窗口添加实例

前面两个小节都是从源码的角度来分析WindowManagerService对窗口的管理，而本小节将通过一个具体的例子来加深大家的理解。范例很简单，即从Launcher2中点击Gallery图标来启动这个应用程序。我们将在WindowManagerService的适当位置中加上调试Log，以方便读者了解整个流程中的各种状态变化。

我们知道，当Gallery这个Activity即将显示时，它需要通过一系列的函数调用最终进入WMS的addWindow（这一过程就不再赘述了）中。这时WMS的WindowList中还不存在Gallery所对应的WindowState，如图10-10所示。

WindowManager	1206,addwindow begin,client= android.view.ViewRootImpl$W@412156c0,viewVis=0
WindowManager	1206,addwindow,before,i=4,w=Window{412529d0 RecentsPanel paused=false},surfacestate=0
WindowManager	1206,addwindow,before,i=3,w=Window{411f6280 StatusBar paused=false},surfacestate=4
WindowManager	1206,addwindow,before,i=2,w=Window{412455a0 Keyguard paused=false},surfacestate=0
WindowManager	1206,addwindow,before,i=1,w=Window{413530f0 com.android.launcher/com.android.launcher2.Launcher paused=true},surfacestate=4
WindowManager	1206,addwindow,before,i=0,w=Window{411cf648 com.android.systemui.ImageWallpaper paused=false},surfacestate=4

▲图10-10　添加Gallery窗口前的状态

上面这段Log中，“addwindow begin”被放在函数addWindow的开头；“addwindow,before”紧随其后，表示在addWindow执行具体操作前的情况。我们依次打印出了当前系统中所有WindowState的信息（也就是WindowList列表中的所有元素），以及它们的Surface状态。

Surface是窗口能真正显示到物理屏幕上的基础，由SurfaceFlinger管理，我们在后续小节会专门介绍。先来看看它有哪些状态，具体如表10-7所示。

表10-7　Surface的状态

State	Value	Description
NO_SURFACE	0	Surface还没有创建
DRAW_PENDING	1	Surface已经创建，但窗口还没有开始绘制，所以Surface实际上处于隐藏状态

COMMIT_DRAW_PENDING	2	窗口已经第一次绘制完毕，但Surface还没有开始显示，它将在下一次的layout中被显示出来
READY_TO_SHOW	3	窗口绘制请求已经提交，但还在等待其他因素。这有点类似于进程已经处于Ready状态，随时等待CPU分配时间片后执行
HAS_DRAWN	4	窗口已经第一次显示在屏幕上

我们以图10-11来形象地表示上面的Log信息。

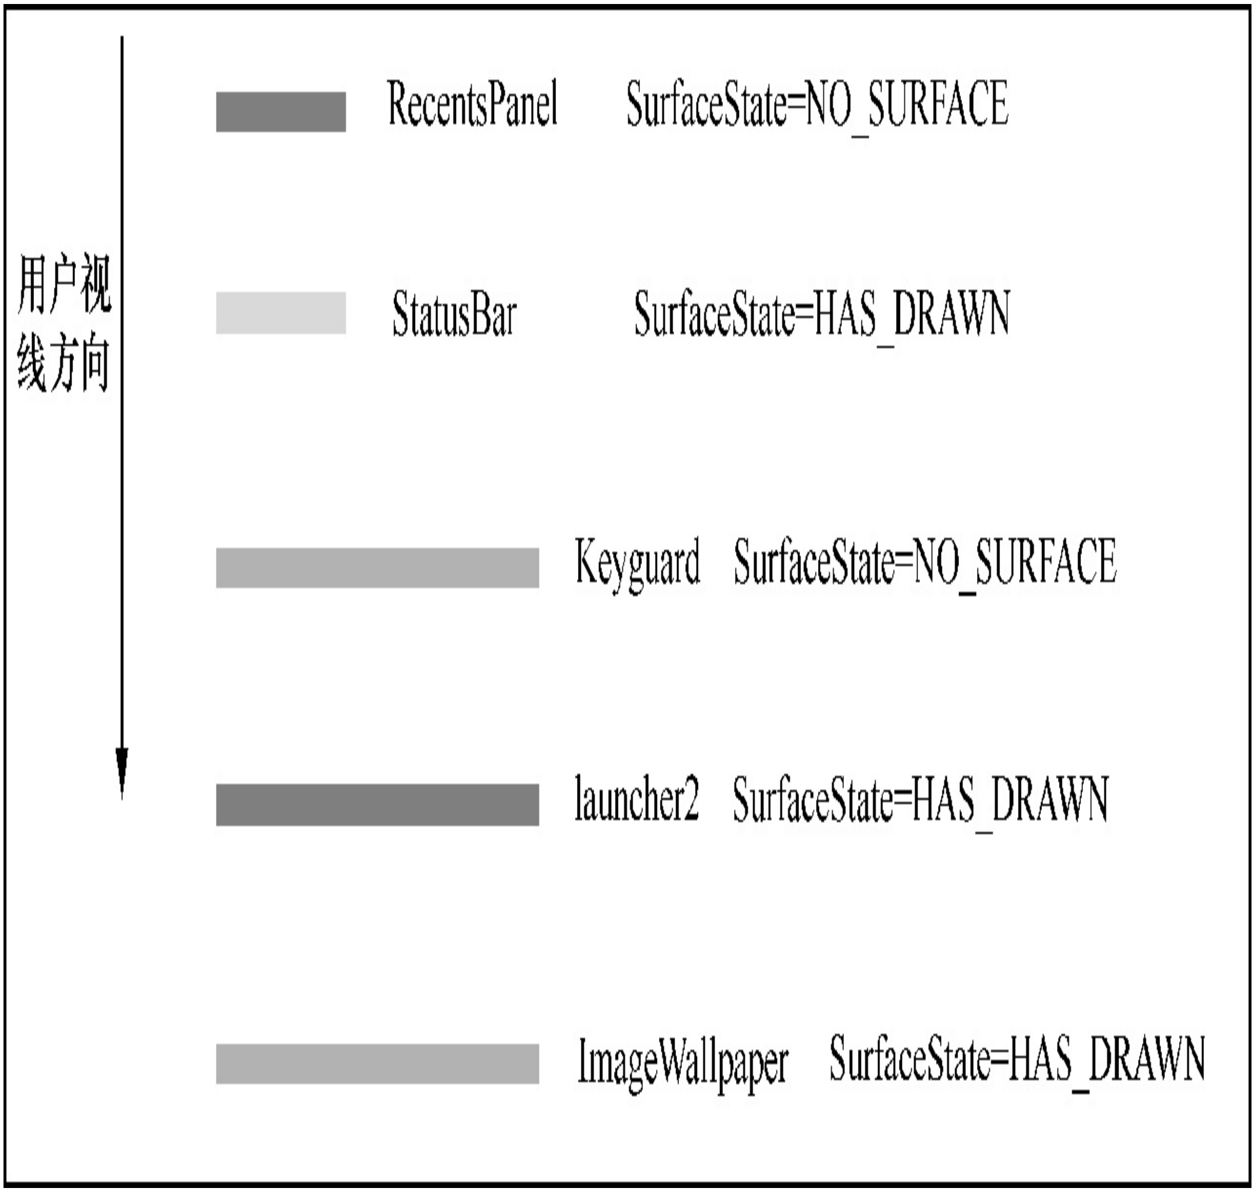

▲图10-11　未添加Gallery窗口前WindowList中的状态

从图10-11中可以清晰地看到，当前拥有Surface的只有3个应用，即StatusBar，launcher2和ImageWallpaper；而且此时Gallery还没有分配到WindowState。

Gallery执行完addWindow后，系统中的WindowState发生了变化，如图10-12所示。

WindowManager	1206,addwindow,end,i=5,w=Window{412529d0 RecentsPanel paused=false},surfacestate=0
WindowManager	1206,addwindow,end,i=4,w=Window{411f6280 StatusBar paused=false},surfacestate=4
WindowManager	1206,addwindow,end,i=3,w=Window{412455a0 Keyguard paused=false},surfacestate=0
WindowManager	1206,addwindow,end,i=2,w=Window{4122d288 Starting com.android.gallery paused=false},surfacestate=0
WindowManager	1206,addwindow,end,i=1,w=Window{413530f0 com.android.launcher/com.android.launcher2.Launcher paused=true},surfacestate=4
WindowManager	1206,addwindow,end,i=0,w=Window{411cf648 com.android.systemui.ImageWallpaper paused=false},surfacestate=4

▲图10-12　添加Gallery窗口后的状态

上述Log信息中，“addwindow,end”加在addWindow函数的末尾，表示函数执行结束后的变化情况。

我们也用图10-13所示的形式表示出来。

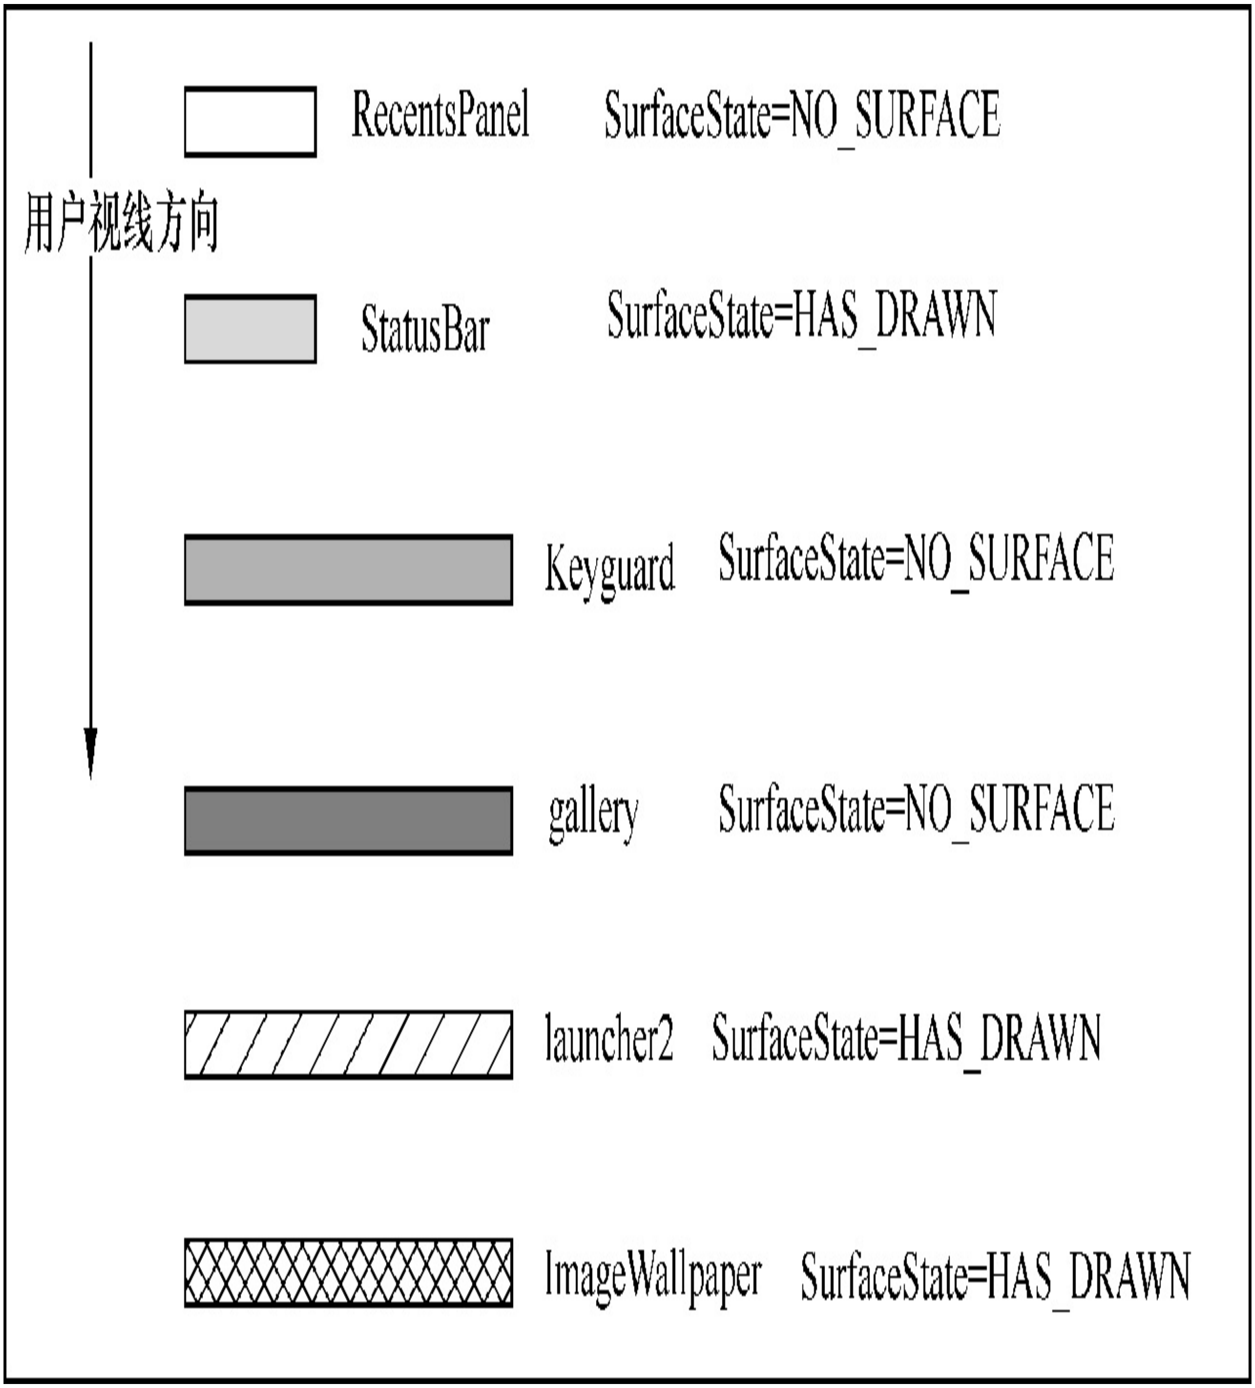

▲图10-13　添加Gallery窗口后WindowList中的状态

Gallery和Launcher2，ImageWallpaper的窗口类型属于同等级。根据前面讲解的“层级值”分配规则，后启动的应用程序优先级高，所以gallery最终排在了launcher2和壁纸的上方。不过这时候它还没有申请到Surface——这个工作要等到用户调用WMS中的relayoutWindow时才会

实施；而且我们要注意的是gallery的这行Log，如图10-14所示。

```
WindowManager    1206,addwindow,end,i=2,w=Window{4122d288 Starting com.android.gallery pau
                 sed=false},surfacestate=0
```

▲图10-14　gallery的这行Log

上面标注的是“Starting com.android.gallery”，为什么呢？因为当新窗口即将显示前（注意：并不是所有新窗口都有启动窗口），Android系统会自动为其加上一个启动窗口，目的就是使整个启动过程看起来更加流畅，从而增强用户的体验。我们会在稍后的小节中做专门的介绍。

当程序继续运行时，会进入relayoutWindow（参见后续小节的分析）来申请Surface。和addWindow中的处理一样，我们在函数relayoutWindow的首尾加上Log来进行比较。

进入relayoutWindow时，如图10-15所示。

```
WindowManager    1206,relayoutWindow,before,i=2,w=Window{4124d458 Starting com.android.gal
                 lery paused=false},surfacestate=0
```

▲图10-15　进入relayoutWindow时

结束relayoutWindow时，如图10-16所示。

```
WindowManager    1206,relayoutWindow,end,i=2,w=Window{4124d458 Starting com.android.galler
                 y paused=false},surfacestate=1
```

▲图10-16　结束relayoutWindow时

可以看到，relayoutWindow给gallery的启动窗口分配了Surface，因而它的状态变为DRAW_PENDING；而且随后gallery的真正窗口也会通过addWindow来申请窗口，如图10-17所示。

WindowManager	1206,addwindow,end,i=6,w=Window{4124b848 RecentsPanel paused=false},surfacestate=0
WindowManager	1206,addwindow,end,i=5,w=Window{41205c10 StatusBar paused=false},surfacestate=4
WindowManager	1206,addwindow,end,i=4,w=Window{4111c260 Keyguard paused=false},surfacestate=0
WindowManager	1206,addwindow,end,i=3,w=Window{4124d458 Starting com.android.gallery paused=false},surfacestate=4
WindowManager	1206,addwindow,end,i=2,w=Window{4111f120 com.android.gallery/com.android.camera.GalleryPicker paused=false},surfacestate=0
WindowManager	1206,addwindow,end,i=1,w=Window{410f8628 com.android.launcher/com.android.launcher2.Launcher paused=false},surfacestate=4
WindowManager	1206,addwindow,end,i=0,w=Window{41250c40 com.android.systemui.ImageWallpaper paused=false},surfacestate=4

▲图10-17　通过addWindow来申请窗口

此时整个系统中就有7个窗口存在。前面的gallery启动窗口这时已经显示出来，而新增的gallery窗口的Surface状态为NO_SURFACE。很明显，它后面也要通过relayoutWindow来创建一个可用的Surface，如图10-18所示。

WindowManager	1206,relayoutWindow,before,i=3,w=Window{4124d458 Starting com.android.gallery paused=false},surfacestate=4
WindowManager	1206,relayoutWindow,before,i=2,w=Window{4111f120 com.android.gallery/com.android.camera.GalleryPicker paused=false},surfacestate=0
WindowManager	1206,relayoutWindow,end,i=3,w=Window{4124d458 Starting com.android.gallery paused=false},surfacestate=4
WindowManager	1206,relayoutWindow,end,i=2,w=Window{4111f120 com.android.gallery/com.android.camera.GalleryPicker paused=false},surfacestate=1

▲图10-18　通过relayoutWindow来创建一个可用的Surface

那么，启动窗口在什么情况下消失呢？答案就是当gallery的真正窗口可以显示时——此时它的启动窗口就可以“光荣退休”了。另外，我们还可以从这些Log中注意到gallery的前一个应用（即launcher2）的变化情况，如图10-19所示。

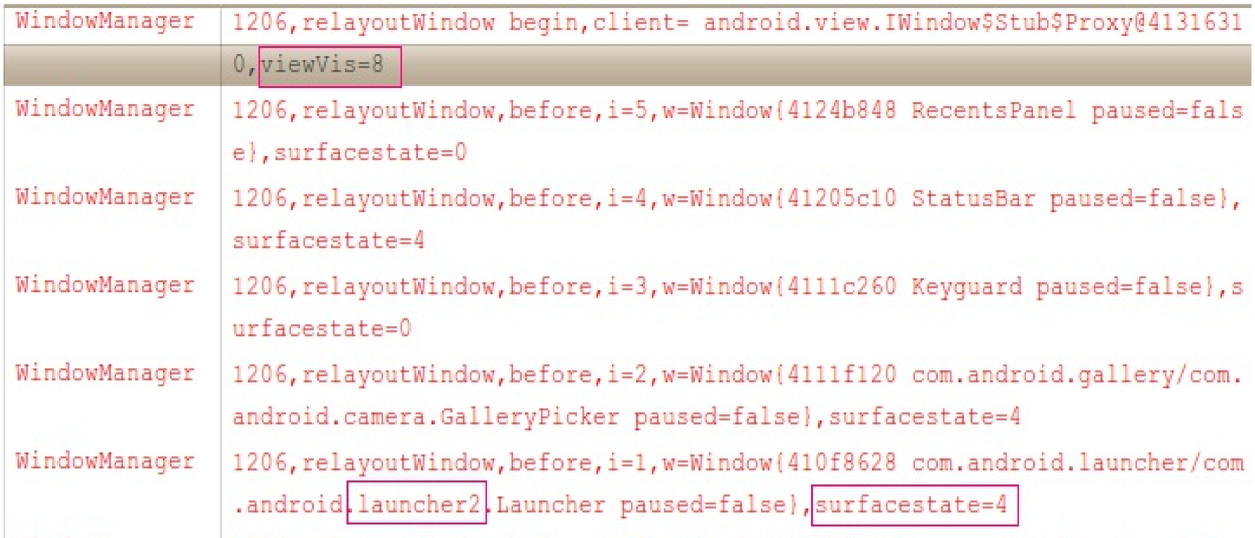

▲图10-19　gallery的前一个应用（即launcher2）的变化情况

图中第一个方框描述的是relayoutWindow()的第七个参数，即：

```
public int relayoutWindow(Session session, IWindow client, in
       WindowManager.LayoutParams attrs, int requestedWidth,
       int requestedHeight, int viewVisibility, int flags,
       Rect outFrame, Rect outOverscanInsets, Rect outContent
       Rect outVisibleInsets, Configuration outConfig, Surfac
```

各viewVisibility的状态值定义如表10-8所示。

表10-8　Visibility状态值（在View.java中定义）

State	Value	Description
VISIBLE	0x00000000	当前为可见状态
INVISIBLE	0x00000004	当前不可见，但它仍然占据空间
GONE	0x00000008	不可见，且不占据空间

此时relayoutWindow执行的是“GONE”请求，具体对象为launcher2。最终结果如图10-20所示。

WindowManager	1206,relayoutWindow,end,i=2,w=Window{4111f120 com.android.gallery/com.android.camera.GalleryPicker paused=false},surfacestate=4
WindowManager	1206,relayoutWindow,end,i=1,w=Window{410f8628 com.android.launcher/com.android.launcher2.Launcher paused=false},surfacestate=0

▲图10-20　结果图

可见，当gallery窗口显示出来时，launcher2的Surface就被destroy掉了。因为launcher2此时已经完全被gallery覆盖，没有必要占用Surface资源。

本小节通过一个简单的例子，向读者展示了应用程序切换过程中WMS里各窗口状态的变化，还包括了Surface的状态变迁。建议读者结合前两个小节的源码来综合理解。

10.4　Surface管理

通过前一小节的范例，读者应该对Surface（注意：这里说的是Java层的Surface类，以区别于OpenGL ES的本地窗口Surface）有了初步的印象。接下来我们要解决如下问题：

- Surface与Window的区别；
- Surface的管理；
- Surface的内部实现。

10.4.1　Surface申请流程（relayout）

WMS原则上只负责管理"窗口"的层级和属性，而SurfaceFlinger才是真正将窗口数据合成并最终显示到屏幕上的系统服务。由此可见，WMS在对窗口（比如大小、Z-Order）做出调整的同时，也必须要通知SurfaceFlinger，这样才能把正确结果及时地呈现给"观众"。

根据SurfaceFlinger中学习过的知识，UI界面的绘制需要有"画板"，即BufferQueue的支持。所以无论是系统窗口，还是应用窗口，都必须向SurfaceFlinger申请相应的Layer，进而得到图形缓冲区的使用权。

那么这一切的起点在哪里呢？没错，还是在ViewRoot中。

当ViewRoot进行performTraversals时，会向WMS申请一个Surface：

```
/*frameworks/base/core/java/android/view/ViewRootImpl.java*/
private void performTraversals() {…
    relayoutResult = relayoutWindow(params, viewVisibility, inset
    …
}
private int relayoutWindow(WindowManager.LayoutParams params, int
boolean insetsPending) throws RemoteException {…
       int relayoutResult = mWindowSession.relayout(
              mWindow, mSeq, params,
              (int) (mView.getMeasuredWidth() * appScale + 0.5f),
              (int) (mView.getMeasuredHeight() * appScale + 0.5f)
              viewVisibility, insetsPending ? WindowManagerGlobal
```

```
            mWinFrame, mPendingOverscanInsets, mPendingContentI
            mPendingConfiguration, mSurface);
```

当ViewRoot在performTraversals时，如果发现是第一次执行这个函数（或者窗口的可见性、大小等属性发生了变化），那么它就会调用relayoutWindow。从名称可以看出，这个函数会“重新布局”窗口——简而言之，就是应用进程通过IWindowSession.relayout来让WMS向SurfaceFlinger申请“画板”，然后通过上述代码段中的mSurface变量将结果值返回。

要特别注意这个mSurface变量，实际上在ViewRoot中已经分配了一个初始的Surface对象。

```
private final Surface mSurface = new Surface();
```

既然如此，为什么还要通过WMS再分配一次呢？

因为初始时得到的Surface是“空壳”。换句话说，其内部没有承载UI数据的“画板”，所以如果直接使用它来绘图是无效的。只有经过relayout()重新赋值后，它才有意义。

那么，如何让WMS为应用进程分配一个有效的Surface呢？

大家应该还记得在SurfaceFlinger章节中，我们曾经分析过GraphicBuffer是如何在应用进程和SurfaceFlinger进程中保持高度一致的。这里的情况类似，只不过前者是C++语言实现的，而后者则是通过Java语言编写的。Java层的Binder服务通常使用aidl来描述，如IWindowSession.aidl。其中relayout的函数声明如下：

```
        int relayout(IWindow window, int seq, in WindowManager.La
            int requestedWidth, int requestedHeight, int viewVisi
            int flags, out Rect outFrame, out Rect outOverscanIns
            out Rect outContentInsets, out Rect outVisibleInsets,
            out Configuration outConfig, out Surface outSurface);
```

可以看到，outSurface这个参数前面有一个out标志，说明它是一个函数出参。一旦aidl发现了这个out属性，它就会做特殊处理。具体而言，就是当aidl工具生成java文件时，会为应用端的proxy和服务端的Stub考虑此参数的parcable因素。具体如下所示。

（1）Stub:

```
…
android.view.Surface _arg11;
_arg11 = new android.view.Surface(); //新建一个Surface对象
int _result = this.relayout(_arg0, _arg1, _arg2, _arg3, _arg4, _a
…
if ((_arg11!=null)) {//对_arg11(即Surface对象)进行处理
reply.writeInt(1);
_arg11.writeToParcel(reply,android.os.Parcelable.PARCELABLE_WRITE_
}
```

从上面的代码片段可以看出，服务器首先在其进程空间中新建了一个Surface对象，然后调用WMS来为这个对象赋值。但是这个对象和客户端最终收到的对象并不是同一个——奥妙在函数末尾，也就是我们调用了_arg11（即Surface）中的writeToParcel方法。这也同时告诉我们，如果一个Class类希望作为aidl函数中的out参数，它就必须要继承自Parcelable并实现writeToParcel这一关键方法。对于Surface来说，它对这个接口方法的实现是在JNI层的，即android_view_Surface.cpp中。

（2）与上面相对应，客户端就必须要实现readFromParcel了。如下:

```
Proxy:
public int relayout(…, android.view.Surface outSurface) throws an
{…
android.os.Parcel _reply = android.os.Parcel.obtain();
…
mRemote.transact(Stub.TRANSACTION_relayout, _data, _reply, 0);//远
…
if ((0!=_reply.readInt())) {
outSurface.readFromParcel(_reply);//读取结果值
}
```

至于两边的Surface对象又是如何保持一致性的，其基本原理和SurfaceFlinger中的GraphicBuffer类似，后续小节也有详细解释。

接下来我们深入relayoutWindow的源码实现来一探究竟。这个函数很长，大家重点关注它对Surface对象的处理。根据上面的分析，我们能推测出它的工作分为两种情况。

- viewVisibility为VISIBLE的情况

这种情况下，用户请求生成一个用于显示的有效Surface（如前一小节范例中的gallery）。

- viewVisibility为GONE的情况

这种情况通常意味着窗口即将退出显示，因而就要销毁用户已经持有的Surface（如前一小节范例中的launcher2）。

本小节集中分析viewVisibility为VISIBLE的情况：

```
public int relayoutWindow(Session session, IWindow client, in
        WindowManager.LayoutParams attrs, int requestedWidth,
        int requestedHeight, int viewVisibility, //窗口可见性请
        int flags, Rect outFrame, Rect outOverscanInsets, Rec
        Rect outVisibleInsets, Configuration outConfig, Surfa
    boolean toBeDisplayed = false;//此窗口是否要显示，由多个因素决
    boolean inTouchMode;
    boolean configChanged;//配置是否发生了变化
    boolean surfaceChanged = false;//Surface是否发生了变化
    boolean animating;
    …
    synchronized(mWindowMap) {//访问到共享资源，注意同步
       WindowState win = windowForClientLocked(session, clien
       …
       WindowStateAnimator winAnimator = win.mWinAnimator;//私
       if (win.mRequestedWidth != requestedWidth|| win.mReque
           win.mLayoutNeeded = true;//尺寸发生变化，需要重新layou
           win.mRequestedWidth = requestedWidth;
           win.mRequestedHeight = requestedHeight;
       }
       …//对于窗口属性等因素的调整，代码省略
      if (viewVisibility == View.VISIBLE && (win.mAppToken ==
              || !win.mAppToken. clientHidden)) {
           toBeDisplayed = !win.isVisibleLw();//假如已经是可见状
           …
           if (toBeDisplayed) {//如果最终的判断结果是需要显示
               if (win.isDrawnLw() && okToDisplay()) {
                   winAnimator.applyEnterAnimationLocked();
               }
               …
           }
           …
           try {
```

```
                if (!win.mHasSurface) {
                    surfaceChanged = true;
                }
                SurfaceControl surfaceControl = winAnimator.cr
                if (surfaceControl != null) {
                    outSurface.copyFrom(surfaceControl);//将生成
                    …
                } else {
                    outSurface.release();//生成Surface失败
                }
            } catch (Exception e) {…
            }
            …
            }
        } else {…//viewVisibility不是VISIBLE的情况
        }
        …
        performLayoutAndPlaceSurfacesLocked();
  …
 }
```

设想一下这个函数将会遇到的情况：

- 首先它需要判断这个窗口是否要显示。这既取决于入参中viewVisibility的具体请求，同时也取决于这个窗口状态是否适合visible状态以及当前是否已经为visible(isVisibleLw)。最终的判断结果由toBeDisplayed表示。
- 如果是要显示的窗口，那么它就得有合法的Surface。因而如果这个窗口之前还未持有Surface或者Surface的属性已经发生了改变，那就要重新申请。最终的判断结果由surfaceChanged来表示。
- 除此之外，它还要判断配置是否变更，以configChanged来表示。
- 如果当前正在进行动画，情况又会稍微不同，animating用于记录这种情况。
- 函数参数中，requestedWidth和requestedHeight表示用户请求的宽高，这将影响它申请到的Surface的属性。最后几个以“out”开头的变量表明它们也是出参，如outFrame，outSurface等。

函数relayoutWindow首先从mWindowMap中查找出与client对应的WindowState对象，即调用windowForClientLocked函数。在判断窗口是否visible时，主要的依据是Surface状态、是否正在进行退出动画等。

注意如果窗口当前已经是visible就不用再显示了，因而toBeDisplayed是取反操作。

假如当前窗口正在执行退出动画，或者它已经进入destroy列表，就要撤销这些操作。另外，如果之前的状态是GONE，我们还要执行一个进入动画。这一部分工作由WindowStateAnimator来全权负责，每一个WindowState中都有一个mWinAnimator来处理这些动画效果。我们将在后面小节专门介绍其中的实现细节。

如果确定窗口即将要显示，还需要执行一系列前期的准备操作，如显示数据是否准备好、屏幕是否开启、配置是否有变化等；而且假如图形格式改变，即便之前已经有可用的Surface也要重新创建——这种情况下必须先destroy老的Surface，然后设置surfaceChanged为true。图形格式由android.graphics.PixelFormat定义，默认是OPAQUE（表示不需要alpha通道）。

整个函数用于配置和判断的内容占了很大一部分篇幅，真正的核心操作如下。

- 生成Surface。
- 分配层值（如果需要的话）。有两种窗口可能会导致层级值的重新分配，即IM窗口和壁纸窗口。
- performLayoutAndPlaceSurfacesLocked（后面小节有专门介绍）。

WMS并没有在内部直接生成可用的Surface对象，而是在WindowStateAnimator中提供了create SurfaceLocked这个接口；同理，Destroy Surface的接口也必定在这个类中，即destroySurfaceLocked：

```
/*frameworks/base/services/java/com/android/server/wm/WindowState
    Surface createSurfaceLocked() {
        if (mSurfaceControl == null) {…
            mDrawState = DRAW_PENDING;//状态改变了
            try { …
                if (DEBUG_SURFACE_TRACE) {//DEBUG时走这个分支
                    …
                } else {
                    mSurfaceControl = new SurfaceControl(mSession
                        attrs.getTitle().toString(),w, h, format,
                }
```

```
            mWin.mHasSurface = true; //已经有可用的Surface了
        } catch (SurfaceControl.OutOfResourcesException e) {
            …
        } catch (Exception e) {
            …
        }
        …
        Surface.openTransaction();//开始一个Transaction，后续小
        try {
            try {
                …//Transaction的中间过程
            } catch (RuntimeException e) {
                …
        } finally {
            Surface.closeTransaction();//Transaction结束
        }
    }
    return mSurface;
}
```

和我们的预想不一样的地方是：createSurfaceLocked也没有直接与SurfaceFlinger产生交集。从逻辑上来分析，这个函数做了两件事：

- new Surface；
- openTransaction/closeTransaction。

看来所有的秘密都包含在这两个步骤中，我们将在下一小节继续分析。

10.4.2　Surface的跨进程传递

在Android的GUI系统中，与Surface相关的类有很多，如Surface.cpp、Surface.java、Isurface、IGraphicBufferProducer等。我们在SurfaceFlinger章节曾专门针对这些类做过比较，希望读者可以区分清楚。

对于Java层的应用程序来说，Surface.java是它们直接使用的绘图“画板”——而这个Java层的Surface对象则需要间接调用底层接口来完成功能，包括Surface(C++)、ISurfaceComposer等与SurfaceFlinger交互沟通的地方都是在本地层实现的，如图10-21所示。

根据“Surface申请流程”中的分析，Surface(Java)对象在两个地方会被创建。即：

- ViewRootImpl

对应的是ViewRootImpl的成员变量mSurface，而且它在一开始就分配了一个“空”的Surface对象。

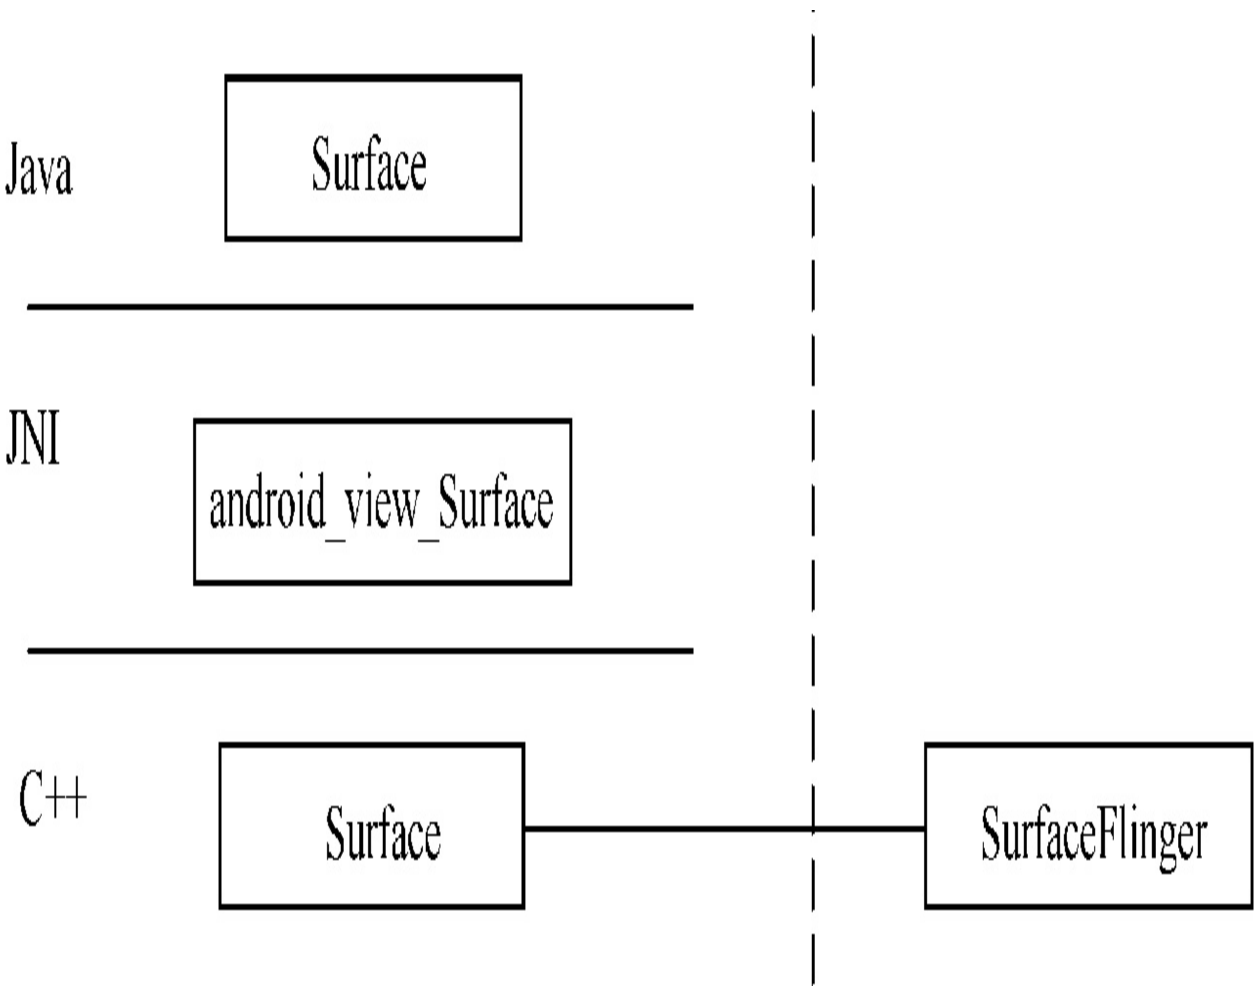

▲图10-21 Surface的实现重点

- WindowStateAnimator

当WMS调用WindowStateAnimator的createSurfaceLocked时，将生成一个真正有效的Surface对象，且由其成员变量mSurfaceControl管理。

那么，为什么说ViewRootImpl初始生成的Surface对象是“空”的呢？要明白这个问题，就得从Surface的初始化入手。Surface的构造函数主要有如下3种形式：

（1）public Surface()；

（2）public Surface(SurfaceTexture surfaceTexture)；

（3）private Surface(int nativeObject)。

其中ViewRootImpl为mSurface初始化时采用的是第一种，即完全不带参数的情况：

```
private final Surface mSurface = new Surface();
```

而WindowStateAnimator中采用的则是通过SurfaceControl间接生成Surface的方式：

```
mSurfaceControl = new SurfaceControl(mSession.mSurfaceSession,
                     attrs.getTitle().toString(),w, h, format, fl
```

这两者最大的区别，就是后一个构造函数还会同时调用名称为“nativeCreate”的本地方法——这其实就是Surface与SurfaceFlinger建立联系的入口。而Java层的Surface类充其量只是一个“壳”，它的所有功能都是通过JNI调用各种本地类来实现的：

```
/*frameworks/base/core/jni/android_view_SurfaceControl.cpp*/
static jint nativeCreate(JNIEnv* env, jclass clazz, jobject sessi
        jstring nameStr, jint w, jint h, jint format, jint flags)
    ScopedUtfChars name(env, nameStr);
    sp<SurfaceComposerClient> client(android_view_SurfaceSession_
    sp<SurfaceControl> surface = client->createSurface(String8(na
                                                         w, h, form
    …
    surface->incStrong((void *)nativeCreate);
    return int(surface.get());
}
```

这里出现了我们熟悉的SurfaceComposerClient——它是SurfaceFlinger派出的“代表”。不论是OpenGL ES还是本小节的Surface，都可以在这个类的协助下有序地申请和访问各Buffer缓冲

区。

上述代码段中直接利用android_view_SurfaceSession_getClient来获取到client对象，这说明在其他地方已经创建了这个对象，并且通过JNI将其保存在了Java层中。具体过程是当addWindow被调用时，WMS会为窗口建立一个WindowState，并将Session保存到它的成员变量mSession中。紧接着WindowState.attach()被调用，此时mSession就通过windowAddedLocked来进一步生成mSurfaceSession；当WindowState构造时，它同时生成内部的mWinAnimator，即WindowState Animator。后者在构造时也将Session对象保存在mSession成员变量中。这个变量将在createSurfaceLocked中传递给Surface的构造函数。这其中的关系有点杂乱，我们特别扩充本节开头的实现图以完整理解，具体如图10-22所示。

通过这个图再来理解nativeCreate，相信读者就清楚多了。

大家可能还有个疑问：既然ViewRootImpl中的mSurface一开始是“空”的，那么后来又是如何变成可用的呢？回答这个问题需要结合前一小节relayoutWindow中的分析。前面已经看到，当WMS端生成一个Surface后，它会通过writeToParcel写入回复reply中。这样当ViewRoot在读取结果值时，就可以利用readFromParcel再把它还原出来。Surface(Java)的readFromParcel将进一步调用JNI方法nativeReadFromParcel，即：

```
/*frameworks/base/core/jni/android_view_Surface.cpp*/
static jint nativeReadFromParcel(JNIEnv* env, jclass clazz, jint
    Parcel* parcel = parcelForJavaObject(env, parcelObj);
    …
    sp<Surface> self(reinterpret_cast<Surface *>(nativeObject));
    sp<IBinder> binder(parcel->readStrongBinder());
    …
    sp<Surface> sur;
    sp<IGraphicBufferProducer>gbp(interface_cast<IGraphicBufferPr
    if (gbp != NULL) {
        sur = new Surface(gbp);//本地的Surface对象与IGraphicBufferP
        sur->incStrong(&sRefBaseOwner);
    }
    …
    return int(sur.get());//这个最终返回的Surface(C++)对象就是有效的
}
```

这样客户端的Surface与一个IgraphicBufferProducer就成功地建立了关系，而后者就是Buffer的管理者，所以后续在此Surface基础上的UI操作最终可以通过SurfaceFlinger显示到屏幕上。

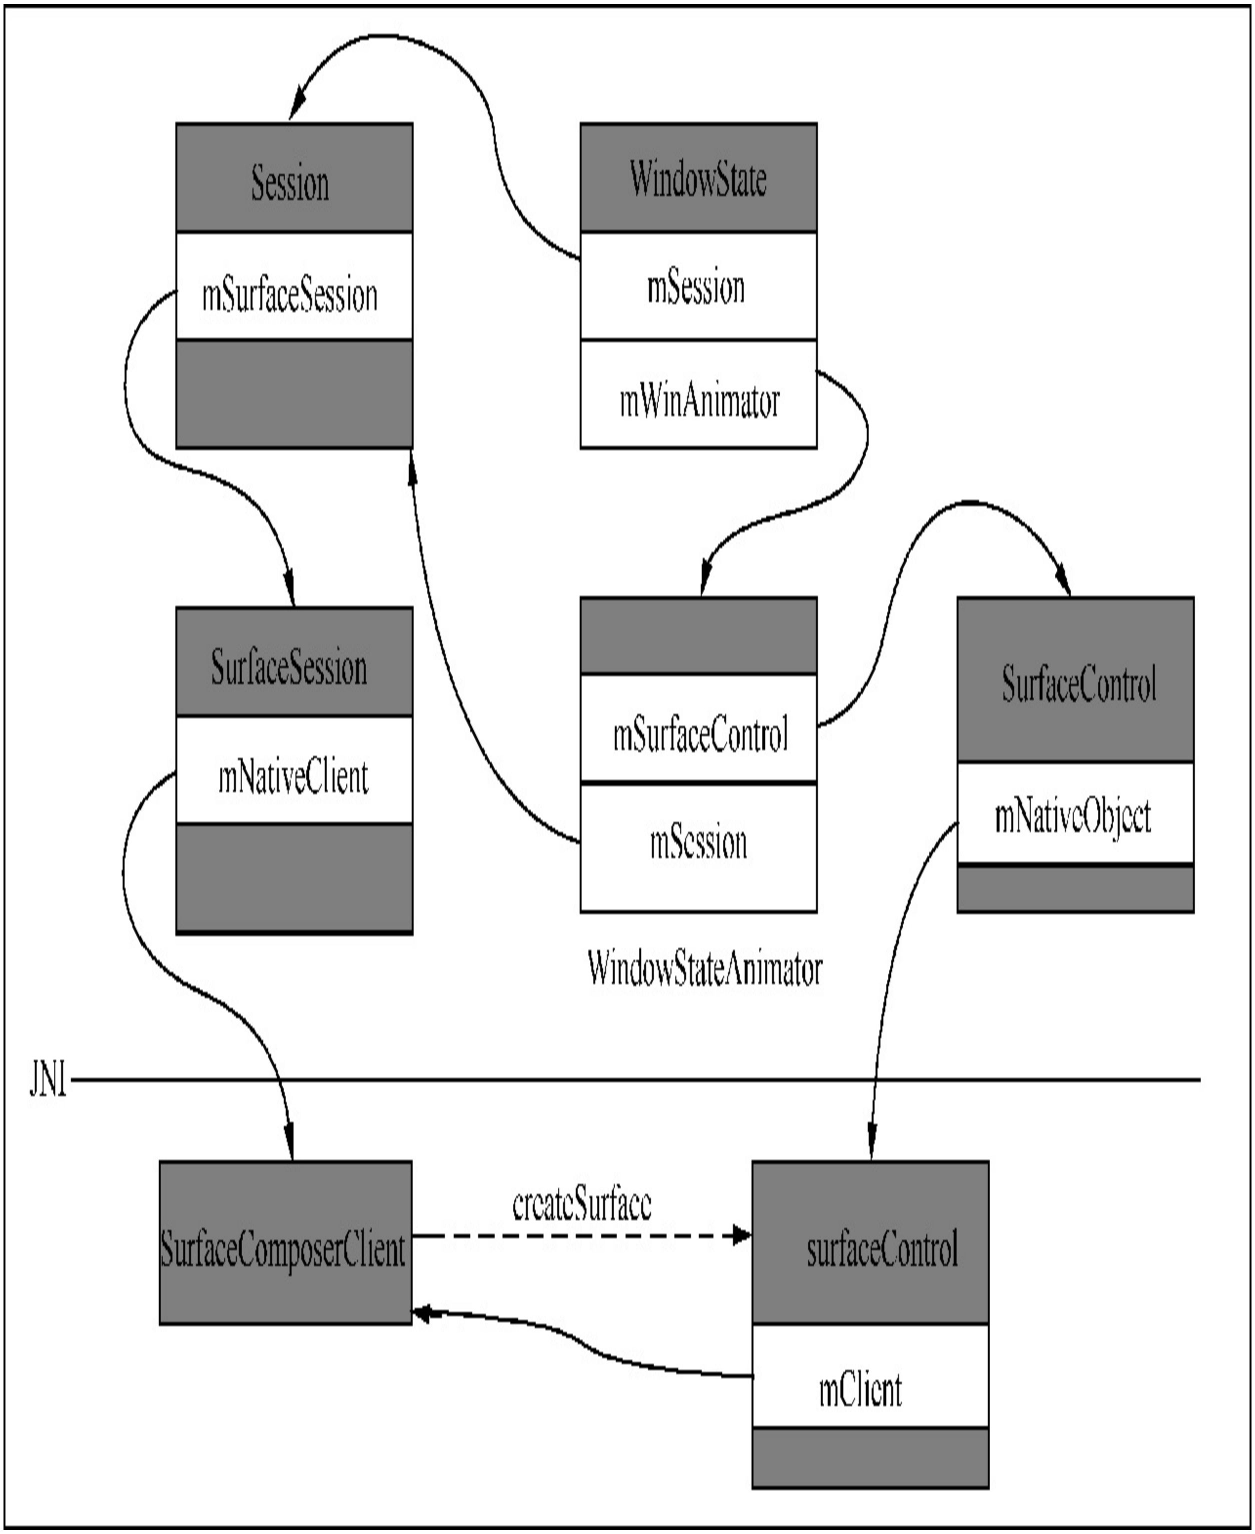

▲图10-22　Surface关系详图

10.4.3　Surface的业务操作

在前两个小节分析WindowStateAnimator. createSurfaceLocked()时，我们发现这个函数的末尾在对SurfaceControl进行操作前，首先是openTransaction，最后结束时再closeTransaction。这部分代码摘录如下：

```
SurfaceControl.openTransaction();
…
mSurfaceControl.setLayerStack(mLayerStack);
mSurfaceControl.setLayer(mAnimLayer);
mSurfaceControl.setAlpha(0);…
SurfaceControl.closeTransaction();
```

那么，这样做的目的是什么？

SurfaceControl提供的这两个方法都分别调用了对应的native本地方法，它们的实现在JNI层：

```
/*frameworks/base/core/jni/android_view_SurfaceControl.cpp*/
static void nativeOpenTransaction(JNIEnv* env, jclass clazz) {
    SurfaceComposerClient::openGlobalTransaction();
}
static void nativeCloseTransaction(JNIEnv* env, jclass clazz) {
    SurfaceComposerClient::closeGlobalTransaction();
}
```

其中openGlobalTransaction的调用流程是：

```
SurfaceComposerClient::openGlobalTransactionComposer::openGlobalT
Composer::getInstance().openGlobalTransactionImpl:
void Composer::openGlobalTransactionImpl() {
    { // scope for the lock
        Mutex::Autolock _l(mLock);
        mTransactionNestCount += 1;
    }
}
```

而SurfaceComposerClient::closeGlobalTransaction()最核心的语句是其在函数末尾调用了Isurface
Composer::setTransactionState()这个接口。换句话说，对于

openGlobalTransaction和closeGlobal Transaction之间的所有设置Surface属性的操作，如setSize，setLayer，setPosition等，都不是及时生效的，而是要等到业务关闭后才统一告知SurfaceFlinger。对于频繁变更属性的地方，这样做一方面可以提高效率，另一方面可以避免属性的过快更新带来一些负面影响，如画面不稳定。

10.5 performLayoutAndPlaceSurfacesLockedInner

前面我们在分析relayoutWindow时，还有一个重要函数没有讲解，就是performLayoutAnd PlaceSurfacesLockedInner（performLayoutAndPlaceSurfacesLocked最终会调用这个函数）。可以说这是整个WindowManagerService中行数最长、最难理解，却也是最核心的一个函数，所以有必要专门用一个小节来对它做详细解析。

从函数名大概可以猜出它的设计意图，即Perform Layout和Place Surface。Layout在这里侧重表达的是“尺寸大小”的意思，即每个窗口所占的空间；后者则与SurfaceFlinger有关——WMS是“导演”，它需要将自己的意图告诉“摄影机”（SurfaceFlinger）。换句话说，观众最终看到的画面是由SurfaceFlinger呈现出来的，从中才能领悟出“导演”的“思想”。大家可以体会下这其中的因果关系。

按照惯例，我们先将函数的“骨架”列出来：

```
/*frameworks/base/services/java/com/android/server/wm/WindowManag
private final void performLayoutAndPlaceSurfacesLockedInner( bool
    SurfaceControl.openTransaction(); //开启/关闭业务的作用前一小节已纟
        try {…
                int repeats = 0;
            do { /*Step1. 第一个循环，处理pendingLayoutChanges*/
                repeats++;
                if (repeats > 6) {//最多尝试次数
                    displayContent.layoutNeeded = false;
                    break;
                }
                …
                if (repeats < 4) {/*Step2.计算窗口大小，如果需要的话*/
                    performLayoutLockedInner (displayContent, repe
                } else {
                    Slog.w(TAG, "Layout repeat skipped after too m
                }
                /*Step3.将Policy应用到各窗口*/
                if (isDefaultDisplay) {
                    mPolicy.beginPostLayoutPolicyLw(dw, dh);
                    for (i = windows.size() - 1; i >= 0; i--) {
                         WindowState w = windows.get(i);
                         if (w.mHasSurface) {
                             mPolicy.applyPostLayoutPolicyLw(w, w.
```

```
                    }
                }
                displayContent.pendingLayoutChanges |=
                                            mPolicy.finishPost
            }
        } while (displayContent.pendingLayoutChanges != 0);
        …
        final int N = windows.size();//所有窗口的数量
        for (i=N-1; i>=0; i--) { /*Step4. 动画相关*/
            …
        }
        …
    } catch (RuntimeException e) {
    } finally {
        SurfaceControl.closeTransaction();//上述的各计算结果统一
    }

    /*****接下来就是收尾工作了***/
    //Step5. 执行应用间切换(app transition)
    …
    //Step6. 销毁所有不再可见的窗口
    …
    //Step7. 是否需要移除已经退出的tokens?
    …
    //Step8. 是否需要移除退出的应用程序?
    …
    scheduleAnimationLocked();
}
```

整个函数逻辑分为两部分：其中try…catch中的代码是对窗口的变更进行计算，并通过SurfaceControl应用到SurfaceFlinger中的过程；剩余部分代码则是做些收尾工作，使WMS中的窗口状态与当前系统保持一致，如移除某些无用的窗口、移除相应的token等。

Step1-3@performLayoutAndPlaceSurfacesLockedInner。这个do...while循环的判断条件是：

```
displayContent.pendingLayoutChanges != 0
```

也就是说，它在执行完一轮操作后，会根据pendingLayoutChanges来得出当前是否还有“pending”（未处理）的“Layout Chanages”——是的话就继续循环（但最多不超过6次。至于为什么是6次，估计是源码作者的经验之谈）；否则就结束循环。

而pendingLayoutChanges 在每轮循环的末尾将由mPolicy.finishPostLayoutPolicyLw重新赋值。这其中涉及很多细节问题，我们将在后续小节解释窗口大小的计算过程时统一讲解。

Step4@performLayoutAndPlaceSurfacesLockedInner。动画相关的计算与判断，我们将在后续小节专门介绍。

Step5-8@performLayoutAndPlaceSurfacesLockedInner，收尾工作。这部分内容比较简单，读者可以自行阅读。

最后，函数末尾通过scheduleAnimationLocked来安排动画的执行。因为Project Butter规定界面刷新要以VSYNC为标准，动画的实施也不例外——它提供了一个mAnimator.mAnimation Runnable来监听VSYNC信号。关于窗口动画的更多细节，可以参考后续小节。

10.6　窗口大小的计算过程

这一小节我们以Activity的窗口为例，完整地分析窗口大小的计算过程，如图10-23所示。

在Android系统中，通常在终端屏幕上看到的界面除了应用程序本身的内容外，至少还可能有以下两个元素，如图10-23所示。

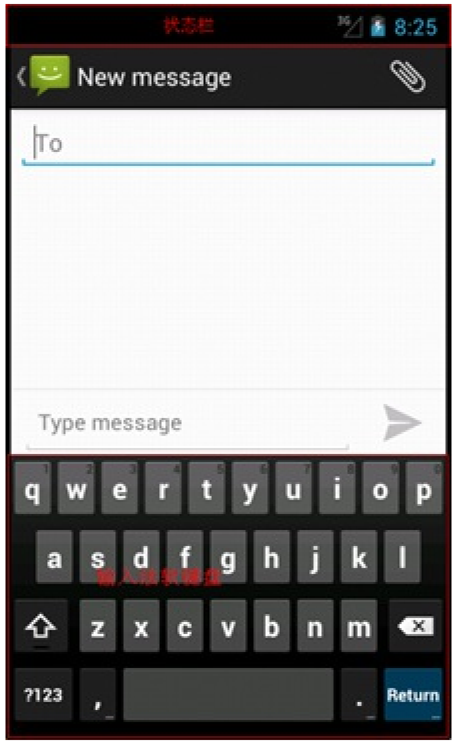

▲图10-23 状态栏、输入法窗口与应用窗口的关系（短信编辑）

- 状态栏

如果应用程序没有特别指明需要全屏显示，则状态栏默认是存在的。这也就意味着对于一块width*height的物理屏幕，实际上可以分配给应用程序的空间尺寸肯定是要小于（或者等于）这个范围的。

- 输入法窗口

开发人员在配置Activity的AndroidManifest.xml时，可以特别指定输入法窗口出现时，应用程序本身的界面是否要“缩小”，以腾出相应的位置来容纳输入法键盘。这个属性称为windowSoftInputMode，如下：

```
<activity …android:windowSoftInputMode=["stateUnspecified","state
                                        "stateHidden","stateAlway
                                        "stateVisible","stateAlwa
                         "adjustUnspecified","adjustResize", "adj
…
</activity>
```

windowSoftInputMode属性的可选值分为两类——以state开头的部分表示当activity成为焦点时软键盘是隐藏或者可见；以adjust开头的值则表示如何调整activity窗口以容纳软键盘。所以这两种类型的配置值是“或”的关系，如表10-9所示。

表10-9　windowSoftInputMode的可选参数

Value	Description
stateUnspecified	输入法软键盘的状态没有特别指定。这意味着系统将自动选择合适的状态值，或者依赖于主题设置
stateUnchanged	软键盘状态取决于它上一次保存的值
stateHidden	设置这个值，软键盘会在某些场景下隐藏（比如当用户启动了activity，而不是因为退出另一个activity后从ActivityStack返回的情况）
stateAlwaysHidden	软键盘总是隐藏
stateVisible	软键盘通常是可见的（和stateHidden情况相同）
stateAlwaysVisible	和上面的stateAlwaysHidden相反
adjustUnspecified	没有指定activity窗口是否要腾出空间来容纳软键盘，系统会自动选择合适的模式。如果窗口内容可以滚动（滚动条），即在很小的

	空间里也能浏览所有内容，那么窗口大小会被重新设置
adjustResize	Activity窗口总是会被重新设置大小，以容纳软键盘
adjustPan	Activity窗口大小不会改变，但窗口内容需要做适当调整，以保证用户可以及时看到自己的输入结果

由上面的分析可知，状态栏和输入法窗口都会影响应用程序窗口大小的计算。前者所占的区域相对固定；输入法窗口的表现则取决于Activity属性的设置。大家可以试着对比上一个“短信编辑窗口”和下面的“通讯录编辑窗口”，如图10-24所示。

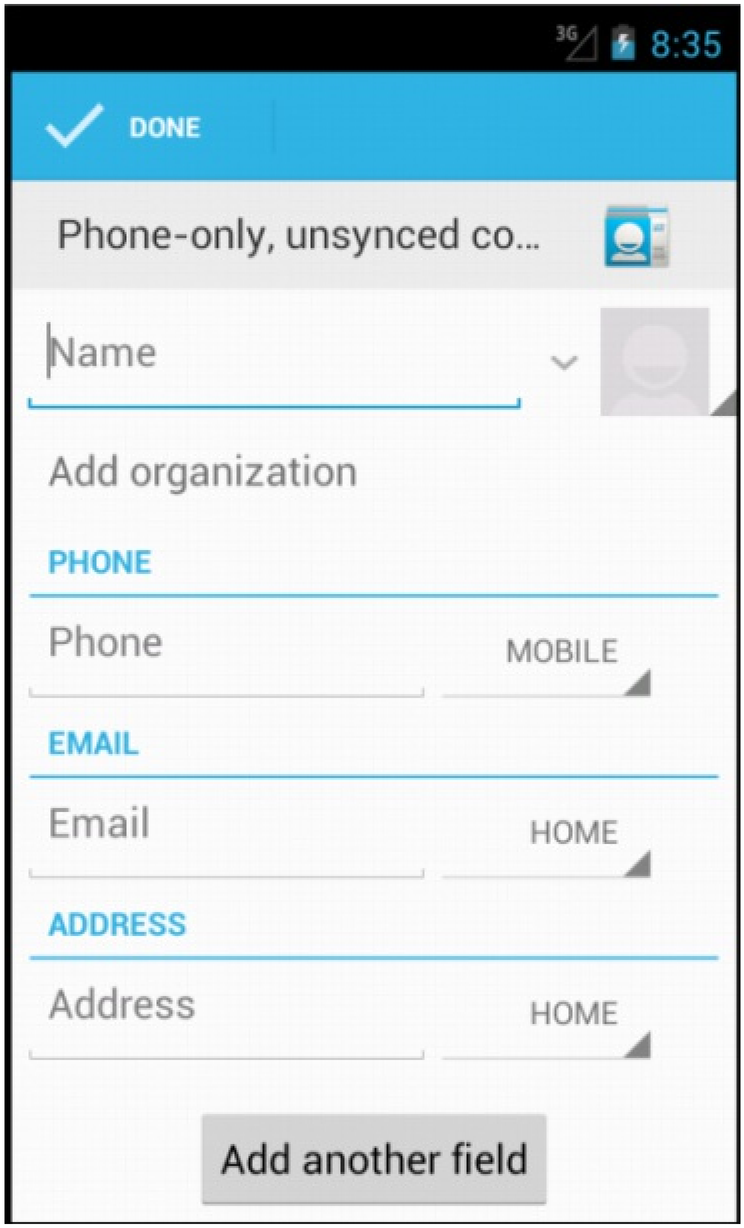

3G
8:35
DONE
Phone-only, unsynced co...
Name
Add organization
PHONE
Phone
MOBILE
EMAIL
Email
HOME
ADDRESS
Address
HOME
Add another field

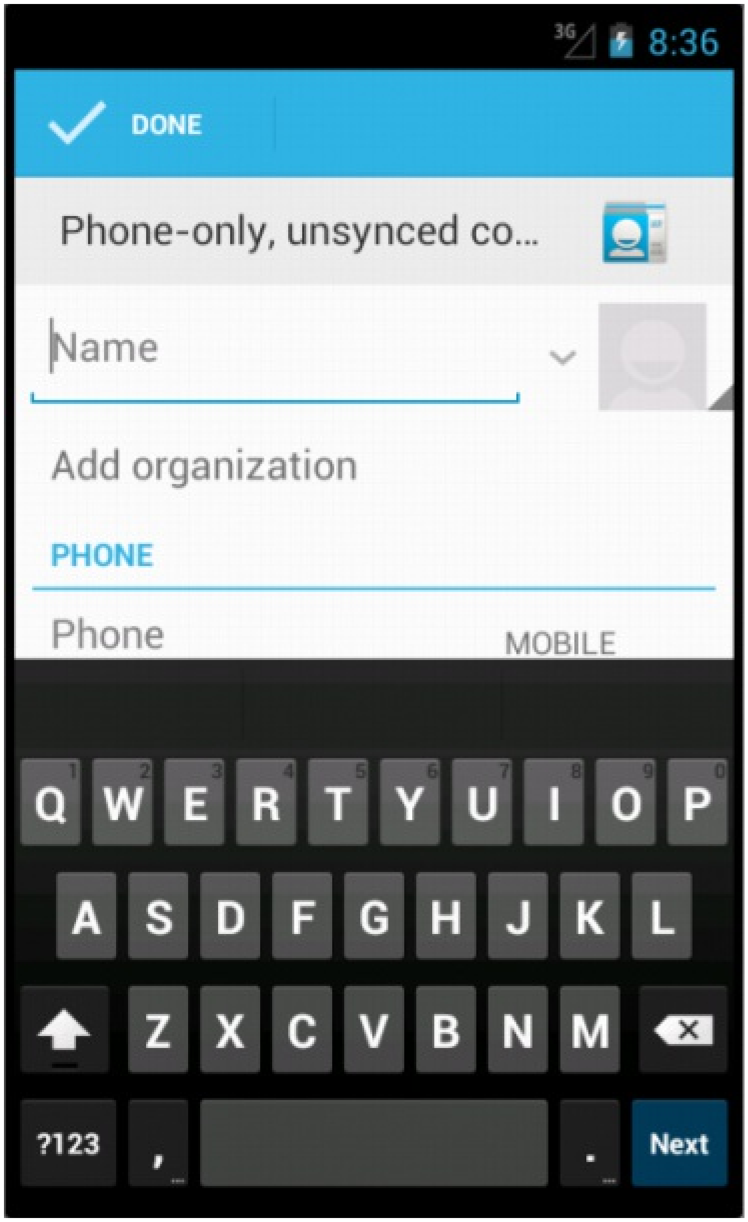

▲图10-24 输入法窗口覆盖了应用窗口的部分区域（通讯录编辑）

窗口大小从理论上讲只有宽和高两个参数。不过从程序设计的角度来考虑，ViewRootImpl还包括了如表10-10所示的相关变量。

表10-10　ViewRootImpl中与窗口大小相关的变量

Member	Description

int mWidth; int mHeight;	当前真实的宽和高
Rect mWinFrame;	当Activity的窗口大小需要改变时，WMS通过W.resized接口通知客户端，mWinFrame就用于记录WMS提供的宽高
Rect mPendingVisibleInsets	同上。也是WMS提供的，用于表示可见区域
Rect mPendingContentInsets	同上。也是WMS提供的，用于表示内容区域
int desiredWindowWidth int desiredWindowHeight	中间值，用于表示“期望”的宽高值，所以和最终的值可能有差异。后面我们还有介绍

ContentInsets通俗地讲是用于显示应用窗口“内容”的区域；而VisibleInsets就是应用窗口“可见”的部分。一般情况下，二者是一致的。不过既然ViewRoot把它们分为两个变量，就说明它们肯定并非完全等同。比如前面“短信编辑”界面，当输入法窗口出现时应用窗口便减小自身尺寸来容纳软键盘，所以内容和可见区域是一样的；“通讯录编辑”的情况则正好相反。应用窗口选择不改变原来大小，所以它的“内容”区域没有变化，只是软键盘覆盖了它的部分可见区域，此时二者的值就不一致了。

ViewRootImpl会在应用程序运行过程中多次调用performTraversals（后一章节有详细介绍），这同时也是计算应用窗口大小的起点。假如是第一次调用这个函数（mFirst为true），那么desiredWindowWidth/desiredWindowHeight的默认值就是物理屏幕大小或者状态栏的配置大小（如果窗口类型为TYPE_STATUS_BAR_PANEL）。

此时程序会调用host.fitSystemWindows(mFitSystem WindowsInsets)来设置4个内边距，其中mFitSystemWindowsInsets的取值来源于mAttachInfo. mContentInsets，后者和mPendingContentInsets表达的是同一个含义，只不过它是当前窗口的真实值。

函数fitSystemWindows被用来通知一个窗口的content inset发生了改变，以使View有机会来适应最新的变化。它会沿着View Tree由上往下传递给各View对象。通常情况下，开发人员并不需要针对这一变化做特别处理，但使用以下两个属性除外：

```
SYSTEM_UI_FLAG_LAYOUT_FULLSCREEN
SYSTEM_UI_FLAG_LAYOUT_HIDE_NAVIGATION
```

为什么呢？我们知道，View组件可以通过setSystemUiVisibility(int)来决定系统UI（包括状态栏、导航栏等）的显示状态。其中有两对容易混淆的值：

SYSTEM_UI_FLAG_FULLSCREEN/SYSTEM_UI_FLAG_**LAYOUT**_FULLSCREEN SYSTEM

从名称来看，它们只相差“LAYOUT”，但实际含义却有很大不同。前者（不带LAYOUT）的值表示用户要求全屏（SYSTEM_UI_FLAG_FULLSCREEN）或者隐藏导航栏（SYSTEM_UI_FLAG_HIDE_NAVIGATION），这样最终的界面中就会是全屏或者不显示导航栏。在这种情况下，应用程序的“内容区域”就要扣除这些系统窗口所占的位置；而后者则只“假设”当前已经是全屏（SYSTEM_UI_FLAG_LAYOUT_FULLSCREEN）或者已经隐藏了导航栏（SYSTEM_UI_FLAG_LAYOUT_HIDE_NAVIGATION）。

对比如图10-25所示。

从图中应该能想到，使用SYSTEM_UI_FLAG_LAYOUT_FULLSCREEN标志有可能导致部分应用界面被遮挡——而有时候这就是我们想要的效果。比如状态栏是半透明的，或者部分区域全透明，那么设置这个属性就可以让用户透过状态栏看到后面的UI界面；否则状态栏中透明的那部分区域就会是黑色的，从而影响用户体验。

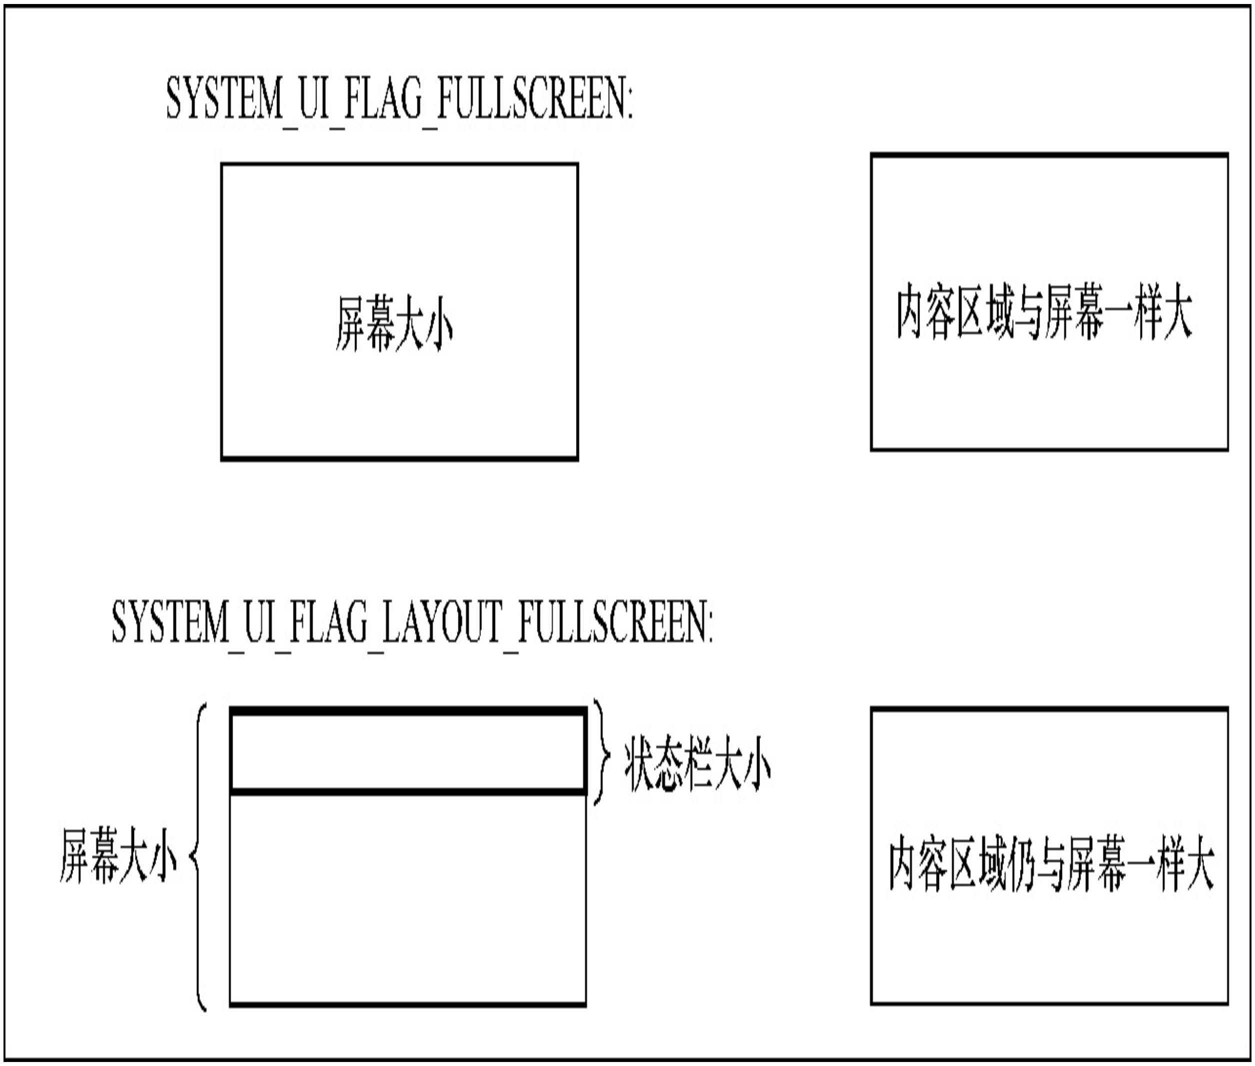

▲图10-25　SYSTEM_UI_FLAG_FULLSCREEN和SYSTEM_UI_FLAG_LAYOUT_FULLSCREEN

对于不希望界面被遮挡的应用程序，我们就需要改写View.fitSystemWindows()以避免出现类似情况。View内部通过mPaddingLeft，mPaddingTop，mPaddingRight和mPaddingBottom来记录内容区域。

我们再回到performTraversals函数的分析中。假如当前不是第一次调用这个函数（mFirst为false），那么desiredWindowWidth和desiredWindowHeight就分别等于mWinFrame.width()和mWinFrame.height()。换句话说，这两个变量表达的是WMS的“desire”。一旦“期望值”与当前的mWidth/mHeight不一致，那么mFullRedrawNeeded，mLayoutRequested和windowSizeMayChange就会被

置为true，这将影响到后面的程序流程。

函数performTraversal()中有一个核心的判断，基于如下几个条件：

```
if (mFirst || windowShouldResize || insetsChanged ||viewVisibilit
```

这几个条件有任何一项满足，就说明窗口的尺寸或者关键属性发生了变化，此时就需要向WMS传递这一消息，即先调用relayoutWindow()，然后进一步调用：

```
int relayout(IWindow window, int seq, in WindowManager.LayoutPara
          int requestedWidth, int requestedHeight, int viewVisibi
          int flags, out Rect outFrame, out Rect outOverscanInset
          out Rect outContentInsets, out Rect outVisibleInsets,
          out Configuration outConfig, out Surface outSurface);
```

这个函数的最后几个参数是出参，也就是WMS的计算结果。包括：

outFrame：WMS得出的应用窗口大小，对应ViewRootImpl中的成员变量mWinFrame。

outOverscanInsets：WMS得出的“过扫描”区域，我们在后续小节会做详细解释。

outContentInsets：WMS得出的content insets，对应ViewRootImpl中的成员变量mPending ContentInsets。

outVisibleInsets：WMS得出的visible insets，对应ViewRootImpl中的成员变量mPending VisibleInsets。

outConfig：WMS得出的窗口配置信息，对应ViewRootImpl中的成员变量mPending Configuration。

outSurface：WMS申请的有效的Surface对象，对应ViewRootImpl中的成员变量mSurface。

根据前面小节的分析，IWindowSession.relayout()最终会导致WMS中的relayoutWindow被调用，这个函数中针对窗口大小的一系列计算流程是：

performLayoutAndPlaceSurfacesLocked()performLayoutAndPlaceS Layout AndPlaceSurfacesLockedInner()。其中最后这个函数在前一小节已经讲解过，我们再把与Layout相关的源码摘录出来：

```
/*frameworks/base/services/java/com/android/server/wm/WindowManag
     private final void performLayoutAndPlaceSurfacesLockedInner(
     SurfaceControl.openTransaction();
          try {…
              int repeats = 0;
              do {//退出循环的条件是displayContent.pendingLayoutChar
                 repeats++;
                 if (repeats > 6) {//循环的最多次数
                     Slog.w(TAG, "Animation repeat aborted after
                     displayContent.layoutNeeded = false;
                     break;
                 }
                 …
                 if (isDefaultDisplay && (displayContent.pendingL
                        & WindowManagerPolicy.FINISH_LAYOUT_REDO_
                     if (DEBUG_LAYOUT) Slog.v(TAG, "Computing new
                     if (updateOrientationFromAppTokensLocked(tru
                         displayContent.layoutNeeded = true;
                         mH.sendEmptyMessage(H.SEND_NEW_CONFIGURA
                      }/*重新计算config*/
                   }

                   if ((displayContent.pendingLayoutChanges
                          & WindowManagerPolicy.FINISH_LAYOUT_RED
                      displayContent.layoutNeeded = true;/*需要重新
                   }
                   if (repeats < 4) {/*这个函数最多被调用4次*/
                       performLayoutLockedInner(displayContent, r
                                                false /*updateInp
                   } else {
                      Slog.w(TAG, "Layout repeat skipped after to
                   }
                   displayContent.pendingLayoutChanges = 0;
                   if (isDefaultDisplay) {
                       mPolicy.beginPostLayoutPolicyLw(dw, dh);
                       for (i = windows.size() - 1; i >= 0; i--)
                          WindowState w = windows.get(i);
                          if (w.mHasSurface) {
                              mPolicy.applyPostLayoutPolicyLw(w,
                          }
                       }
                    displayContent.pendingLayoutChanges |=
                                             mPolicy.finishPostL
```

```
            }
        } while (displayContent.pendingLayoutChanges != 0
…
```

先来看看pendingLayoutChanges的可选值，如表10-11所示。

表10-11　　pendingLayoutChanges可选参数

VALUE	Description
FINISH_LAYOUT_REDO_LAYOUT= 0x0001	Layout状态可能已经改变，所以还要发起另一个layout
FINISH_LAYOUT_REDO_CONFIG = 0x0002	Configuration可能已经改变
FINISH_LAYOUT_REDO_WALLPAPER = 0x0004	壁纸可能需要挪动
FINISH_LAYOUT_REDO_ANIM = 0x0008	需要重新计算动画

从表中可知，各可选参数值是“或”的关系。

在do…while循环中，核心工作都是围绕pendingLayoutChanges展开的。即：

只有当displayContent.pendingLayoutChanges == 0，也就是当前已经没有需要处理的Layout Changes，或者循环次数超限，循环才会退出。不过根据do…while的语法，它至少会执行一次do循环体。在对Layout Change进行处理的过程中：

（1）如果pendingLayoutChanges中带有FINISH_LAYOUT_REDO_CONFIG，那么就通过mH向WMS的消息队列中发送一个SEND_NEW_CONFIGURATION，以重新计算Configuration。

（2）如果pendingLayoutChanges中带有FINISH_LAYOUT_REDO_LAYOUT，就将layout Needed置为true（如果这个变量为false，后续调用performLayoutLockedInner就会直接返回）。

一旦repeats次数小于4，程序将调用performLayoutLockedInner。核心源码如下：

```
private final void performLayoutLockedInner(final DisplayContent
        if (!displayContent.layoutNeeded) {//如果此变量为false，什么
            return;
        }
        displayContent.layoutNeeded = false;//已经执行了本次的layout
        WindowList windows = displayContent.getWindowList();//窗口
        boolean isDefaultDisplay = displayContent.isDefaultDispla
        DisplayInfo displayInfo = displayContent.getDisplayInfo()
        final int dw = displayInfo.logicalWidth;//逻辑宽度，可能比物
        final int dh = displayInfo.logicalHeight;//逻辑高度，可能比物
        …
        final int N = windows.size();//系统中所有窗口数量
        int i;//用于循环计数
        WindowStateAnimator universeBackground = null;
        mPolicy.beginLayoutLw(isDefaultDisplay, dw, dh, mRotation
        …
        int seq = mLayoutSeq+1;//用于与客户端同步
        if (seq < 0) seq = 0;//当seq值超过范围时，重新从0开始循环使用
        mLayoutSeq = seq;//将mLayoutSeq更新为当前的seq值
        …
        int topAttached = -1;
        for (i = N-1; i >= 0; i--) {/*先计算root windows(即没有atta
                                          那些窗口)*/
            final WindowState win = windows.get(i);
            final boolean gone = (behindDream && mPolicy.canBeFor
                    || win.isGoneForLayoutLw();/*假如这个窗口不可见，
                                              退出动画)，那就不浪费时
            …
            if (!gone || !win.mHaveFrame || win.mLayoutNeeded/*mH
                                                               过计算
                    || (win.mAttrs.type == TYPE_KEYGUARD && win.i
                    || win.mAttrs.type == TYPE_UNIVERSE_BACKGROUN
                if (!win.mLayoutAttached) {//为true说明这个窗口是子窗
                    …
```

```
            mPolicy.layoutWindowLw(win, win.mAttrs, null)
            win.mLayoutSeq = seq;
        } else {
            if (topAttached < 0) topAttached = i;/*记录最上
                                                  供下一步使用
        }
    }
  …
}
…
/*接下来开始计算attached window的情况，这些窗口和它们的父窗口关系
for (i = topAttached; i >= 0; i--) {/*直接从上一步中记录的top
                                    中的第一个attached窗口)开始
    final WindowState win = windows.get(i);
    if (win.mLayoutAttached) {…
        if ((win.mViewVisibility != View.GONE && win.mRel
                || !win.mHaveFrame || win.mLayoutNeeded)
           mPolicy.layoutWindowLw(win, win.mAttrs, win.mA
           win.mLayoutSeq = seq;
        }
    }…
}
…
mPolicy.finishLayoutLw();/*结束layout*/
```

从整体逻辑来看，这个函数分为两部分。

- Root Windows

程序首先会处理Root Window，也就是没有依附于其他窗口的那些窗口。因为下一步中子窗口的计算需要建立在它们父窗口的基础上，所以需要优先处理。

- Attached Windows

接着处理子窗口，步骤和Root Window基本一致，不过在调用layoutWindowLw时会传入win.mAttachedWindow作为计算时的参考值。

从流程上看，窗口大小的计算过程如下：

- mPolicy.beginLayoutLw初始化；
- mPolicy.layoutWindowLw执行计算过程；

- mPolicy.finishLayoutLw清理工作。

为什么分为这3个步骤呢？

打个比方，某人上婚恋网站交友，系统为其做“匹配”的流程是：

- 注册者添加自己的个人资料，如职业、爱好等；
- 系统将根据这些个人资料以及“匹配算法”来计算出与其最合适的人；
- 推荐结果等后续操作。

从这个例子中可以发现，系统的“匹配算法”在某个时期内是固定不变的，但是它要针对的对象（注册者）却是千变万化的——这其中的关键就是个人资料，因为每个人都有其特定属性。

Android系统也不例外。它致力于兼容多种设备，因而在设计的过程中一方面会提取产品的“共性”；另一方面要降低不同产品间切换的代价。成员变量mPolicy就是一个实例，它是针对不同产品（如Phone，Tablet等）而制定的窗口策略。窗口大小的计算也属于“Window Policy”的职责之一。

下面我们逐一介绍这3个重要接口。

1．beginLayoutLw

在解释这个函数之前，先要了解PhoneWindowManager中与窗口大小相关的一系列核心变量，如表10-12所示。

表10-12　PhoneWindowManager中与窗口大小相关的核心变量

Member	Description
	Overscan即“过扫描”。有些显示屏（比如电视）可能存在失真现象，且越靠近边缘越

int mOverscanLeft = 0;
int mOverscanTop = 0;
int mOverscanRight = 0;
int mOverscanBottom = 0;
	严重。为了避开这个“固有缺陷”，不少厂商都把扫描调整到画面的5%～10%。这样造成的结果就是画面很可能显示不全，损失的部分称为“Overscan”。与Overscan相关的变量是在新系统版本中加入的（由此也可看出，Android正在进军更多的领域，包括传统家电），分别代表了Overscan区域离屏幕边缘的左、上、右、下边距（注意：是“边距”，如图所示）
	mOverscanXX代表的是边距

intmOverscanScreenLeft, int mOverscanScreenTop; int mOverscanScreenWidth, int mOverscanScreenHeight;	屏幕真实大小，包括了Overscan区域
int RestrictedOverscanScreenLeft, RestrictedOverscanScreenTop, mRestrictedOverscanScreenWidth, mRestrictedOverscanScreenHeight;	类似于mOverscanScreen*，但适当的时候可以移动到Overscan区域
int mUnrestrictedScreenLeft, mUnrestrictedScreenTop， mUnrestrictedScreenWidth, mUnrestrictedScreenHeight;	屏幕的真实大小，不管当前状态栏是否可见，但不包括Overscan区域
intmRestrictedScreenLeft, mRestrictedScreenTop,	屏幕大小，如果状态栏不能

mRestrictedScreenWidth, mRestrictedScreenHeight;	隐藏，它和上述几个变量是不同的
int mSystemLeft, mSystemTop, mSystemRight, mSystemBottom;	所有可见的系统UI元素区域
int mCurLeft, mCurTop, mCurRight, mCurBottom;	包括状态栏、输入法窗口在内的外围尺寸
int mContentLeft, mContentTop, mContentRight,mContentBottom;	内容区域
int mDockLeft, mDockTop, mDockRight, mDockBottom;	输入法窗口区域

beginLayoutLw的作用就是对上面这些变量进行初始化。比如mDockLeft、mContentLeft、mCurLeft和mDockTop、mContentTop、mCurTop的原始值是0；mDockRight、mContentRight、mCurRight是屏幕宽度，而mDockBottom、mContentBottom、mCurBottom是屏幕高度。换句话说，它们都被设置成了“满屏”。

接下来的过程分为两部分，即是否有导航栏以及状态栏。

要注意导航栏的摆放位置是根据实际的屏幕属性来决定的。假如导航栏不能移动且为竖屏，那么导航栏在屏幕底端；否则为横屏，导航栏会被显示在右侧。这样做的目的很简单，就是方便用户的操作。

状态栏的大小是相对固定的，可以通过mStatusBar.computeFrameLw(pf, df, vf, vf)计算具体的值。如果当前状态栏可见，那么很多变量就需要进行调整以防止界面被“遮挡”，包括mContentTop，mCurTop和mDockTop。当然，这只是初始化值，后面

还需要根据用户的配置做进一步调整。

2．layoutWindowLw

初始化完成后，各个变量就处于默认状态了。接下来程序会根据当前的具体配置进行细化，以满足用户的各种需求：

```
/*frameworks/base/policy/src/com/android/internal/policy/impl/Pho
public void layoutWindowLw(WindowState win, WindowManager.LayoutP
       if (win == mStatusBar || win == mNavigationBar) {//状态栏和
           return;//直接返回
       }
       …
       final int fl = attrs.flags;//窗口属性
       final int sim = attrs.softInputMode;//输入法模式，前面分析过了
       final int sysUiFl = win.getSystemUiVisibility();//系统UI的设
       final Rect pf = mTmpParentFrame; //父窗口大小
       final Rect df = mTmpDisplayFrame;//屏幕大小
       final Rect cf = mTmpContentFrame;//内容区域
       final Rect vf = mTmpVisibleFrame;//可见区域
       final boolean hasNavBar = (isDefaultDisplay && mHasNavigat
                        && mNavigationBar != null && mNavigationB
       …
       if (attrs.type == TYPE_INPUT_METHOD) {
           …//输入法窗口的情况比较简单，大家自行分析
       } else {
           if ((fl & (FLAG_LAYOUT_IN_SCREEN | FLAG_LAYOUT_INSET_D
                   == (FLAG_LAYOUT_IN_SCREEN | FLAG_LAYOUT_INSET_
               //Case 1.
           } else if (((fl & FLAG_LAYOUT_IN_SCREEN) != 0 || (sysU
                           & (View.SYSTEM_UI_FLAG_LAYOUT_FULLSCRE
                           | View.SYSTEM_UI_FLAG_LAYOUT_HIDE_NAVI
              //Case 2.
           } else if (attached != null) {
              //Case 3.
           } else {
              //Case 4.
           }
        }
        …
        win.computeFrameLw(pf, df, cf, vf);//通过4个临时变量，计算出
        …
    }
```

因为导航栏与状态栏窗口比较特殊且相对固定，

PhoneWindowManager会在其他地方进行处理，所以如果是这两种类型窗口layoutWindowLw就直接返回。输入法窗口大小的处理也比较简单，读者可以自行分析。

对于其他类型的窗口，总共又分为4种情况，如上述代码段中的“CaseXXX”所示。需要特别指出的是，layoutWindowLw这个函数只负责计算pf、df、cf和vf 4个临时变量，最终的结果还需要由win.computeFrameLw(pf, df, cf, vf)来确认。

Case 1. 设置了FLAG_LAYOUT_IN_SCREEN, FLAG_LAYOUT_INSET_DÉCOR且没有指定FLAG_FULLSCREEN及View.SYSTEM_UI_FLAG_FULLSCREEN

这是应用窗口的典型情况。此时UI界面需要考虑包括状态栏在内的系统元素，这样才能避免被“挡住”。又分为两种情况：

- Case 1.1 子窗口

如果是子窗口，那么各变量的值与其父窗口是一致的，我们可以调用setAttachedWindow Frames来执行实际操作。

- Case 1.2 非子窗口

又可以分为3种情况。

- Case 1.2.1 TYPE_STATUS_BAR_PANEL或者 TYPE_STATUS_BAR_SUB_PANEL

这两者是唯一可以在状态栏上方显示的窗口类型，受到StatusBar Service的权限保护。

- Case1.2.2普通的应用程序窗口（FIRST_APPLICATION_WINDOW～LAST_SUB_WINDOW），并且明确指定了FLAG_LAYOUT_IN_OVERSCAN，说明它希望占据overscan的区域。某些情况下这个标志很有用，如游戏场景。

- Case1.2.3普通的应用程序窗口（FIRST_APPLICATION_WINDOW～ LAST_SUB_WIN DOW），并且明确指定了View标志

SYSTEM_UI_FLAG_LAYOUT_HIDE_NAVIGATION

我们知道，SYSTEM_UI_FLAG_LAYOUT_HIDE_NAVIGATION表示应用程序“假设”了当前导航栏是隐藏的，因而此时部分内容区域有可能会被遮挡覆盖。

- Case 1.2.4其他情况的处理

以上这几种情况都会受到softInputMode的影响。

Case 2. 指定了窗口标志FLAG_LAYOUT_IN_SCREEN，或下面两个View标志的任何一个：
View.SYSTEM_UI_FLAG_LAYOUT_FULLSCREENView.SYSTEM_UI_FLAG_LAYOUT

这种情况说明应用窗口希望满屏显示（可能是没有系统UI元素的满屏，也可能是有系统UI的满屏）。此时又根据不同的窗口类型细化为多种情况，如TYPE_STATUS_BAR_PANEL、TYPE_NAVIGATION_BAR、TYPE_SECURE_SYSTEM_OVERLAY等，不过处理过程大同小异。

Case 3. attached!=null，说明是子窗口的情况。根据前面的分析，直接调用setAttachedWindow Frames即可。

Case 4. 假如上面的情况均不满足，那么就进入这一分支。此时只有两种子情况，即窗口类型是否为TYPE_STATUS_BAR_PANEL。我们说过，这种类型的窗口可以显示在状态栏之上，它的优先级与状态栏本身是一致的。

通过上面几种情况的计算得出的pf，df，cf和vf，还需要通过computeFrameLw进行最终确认。此时得到的才是WindowState中的mParentFrame、mDisplayFrame、mContentFrame和mVisibleFrame。

3．finishLayoutLw

这个函数目前直接返回0，因而是一个空实现，大家可以直接略过。

经过这一系列的函数调用后，WindowManagerService.relayoutWindow才算真正结束了。它会负责将计算结果值通过函数的几

个出参（如outContentInsets、outVisibleInsets、outConfig和outSurface等）告知ViewRoot，从而影响UI程序的显示结果。

10.7　启动窗口的添加与销毁

10.7.1　启动窗口的添加

从图10-26中我们知道，当一个新的Activity启动时系统可能会先显示一个启动窗口——这个窗口会等到Activity的主界面显示出来以后才消失。这样做可以转移用户的注意力，对于启动时间较长的应用程序大有裨益。

很显然这个窗口的启动与销毁是由系统来管理的，涉及了ActivityManagerService和WindowManagerService。我们在本小节会详细分析其中的流程。

当AMS在处理startActivity时，它会调用内部的ActivityStack.startActivityLocked（可以参见AMS章节的描述）。如果变量NH>0，说明我们正在切换到一个新的Task或者另一进程，这时就会准备启动一个Preview Window。不过会受到以下两个因素的制约。

- SHOW_APP_STARTING_PREVIEW

ActivityStack中的一个boolean变量，代表是否要启动预览窗口，默认是true。

- doShow

这个变量默认为true。假如要启动的Activity是在一个新的Task中，且设置了FLAG_ACTIVITY_RESET_TASK_IF_NEEDED，那么我们就要在必要的时候执行reset（即resetTaskIf NeededLocked），然后判断这个Activity是否在mHistory最顶端（并且不在finishing，也没有delayedResume）。只有这些条件都满足，doShow才会是true，否则也不需要添加启动窗口。

一旦确认需要添加启动窗口，ActivityStack紧接着调用WindowManagerService.SetApp StartingWindow，由WMS来安排具体的窗口创建过程。

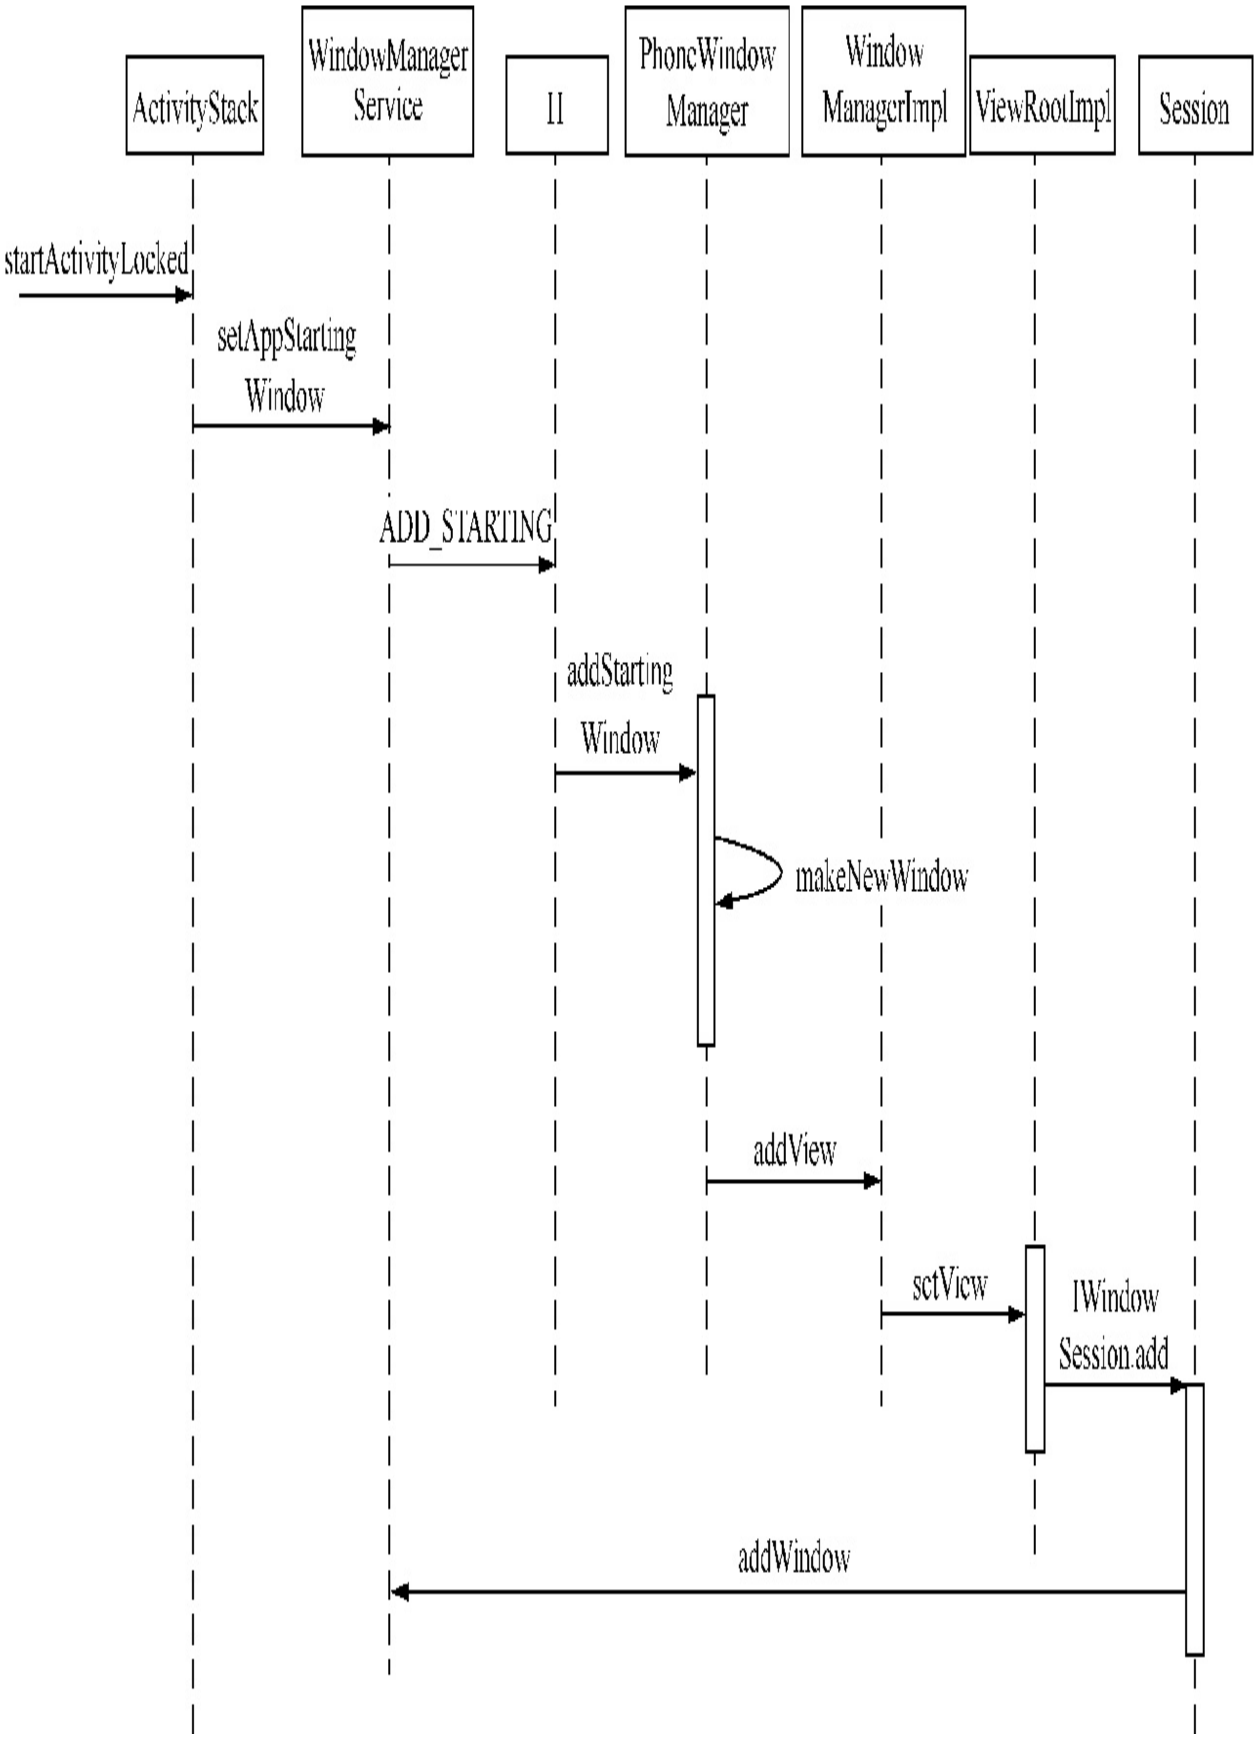
ActivityStack
WindowManager Service
H
PhoneWindow Manager
Window ManagerImpl
ViewRootImpl
Session
startActivityLocked
setAppStarting Window
ADD_STARTING
addStarting Window
makeNewWindow
addView
setView
IWindow Session.add
addWindow

▲图10-26　启动窗口的添加流程

从函数名称可以知道，它用于设置启动窗口的各种参数。主要代码框架如下：

```
/*frameworks/base/services/java/com/android/server/wm/WindowManag
     public void setAppStartingWindow(IBinder token, String pkg,
Compatibili tyInfo compatInfo, CharSequence nonLocalizedLabel, in
int windowFlags, IBinder transferFrom, boolean createIfNeeded) {
      …
      synchronized(mWindowMap) {
          /*Step1. 再次验证是否需要显示启动窗口*/
          AppWindowToken wtoken = findAppWindowToken(token);//应用
          if (wtoken == null) {
              Slog.w(TAG, "Attempted to set icon of non-existing
              return;
          }
          if (!okToDisplay()) {//屏幕的状态是否允许显示？比如屏幕forzen
              return;
          }
          if (wtoken.startingData != null) {//用于存储与启动窗口相关的
              return;
          }
          if (transferFrom != null) {//是否有相关联的启动窗口做参考？
              …
          }
          if (!createIfNeeded) { /*假如不存在关联的启动窗口，且调用者又
                                  那么操作就可以结束了，直接返回*/
              return;
          }
          if (theme != 0) {//Activity的主题不为空
              …
          }
          mStartingIconInTransition = true;
          wtoken.startingData = new StartingData(pkg, theme, comp
                  labelRes, icon, windowFlags);//与启动窗口有关的信息
          Message m = mH.obtainMessage(H.ADD_STARTING, wtoken);
          mH.sendMessageAtFrontOfQueue(m);//将消息投递入栈，以进入下一
      }
    }
```

首先WMS会再次判断是否需要添加启动窗口，它考虑的因素和AMS不同。包括：

- AppWindowToken

因为是Activity的启动窗口，那么它的AppWindowToken一定不能为空。所以当findAppWindowToken(token)时，我们必须得到与token相对应的AppWindowToken。

- 当前屏幕状态

如果显示屏处于frozen或者disabled状态，又或者屏幕背光没有完全打开，那么WMS认为不适合执行启动窗口，此时就会直接中止操作直接返回。

- startingData

AppWindowToken中的startingData用于描述与启动窗口相关的所有信息，如packageName，theme，icon，windowFlags等。这些因素将决定启动窗口的最终效果。

假如wtoken.startingData != null，说明这个Activity已经处理过启动窗口，在这种情况下就不会再继续往下执行了。

接下来函数出现了分支，如图10-27所示。

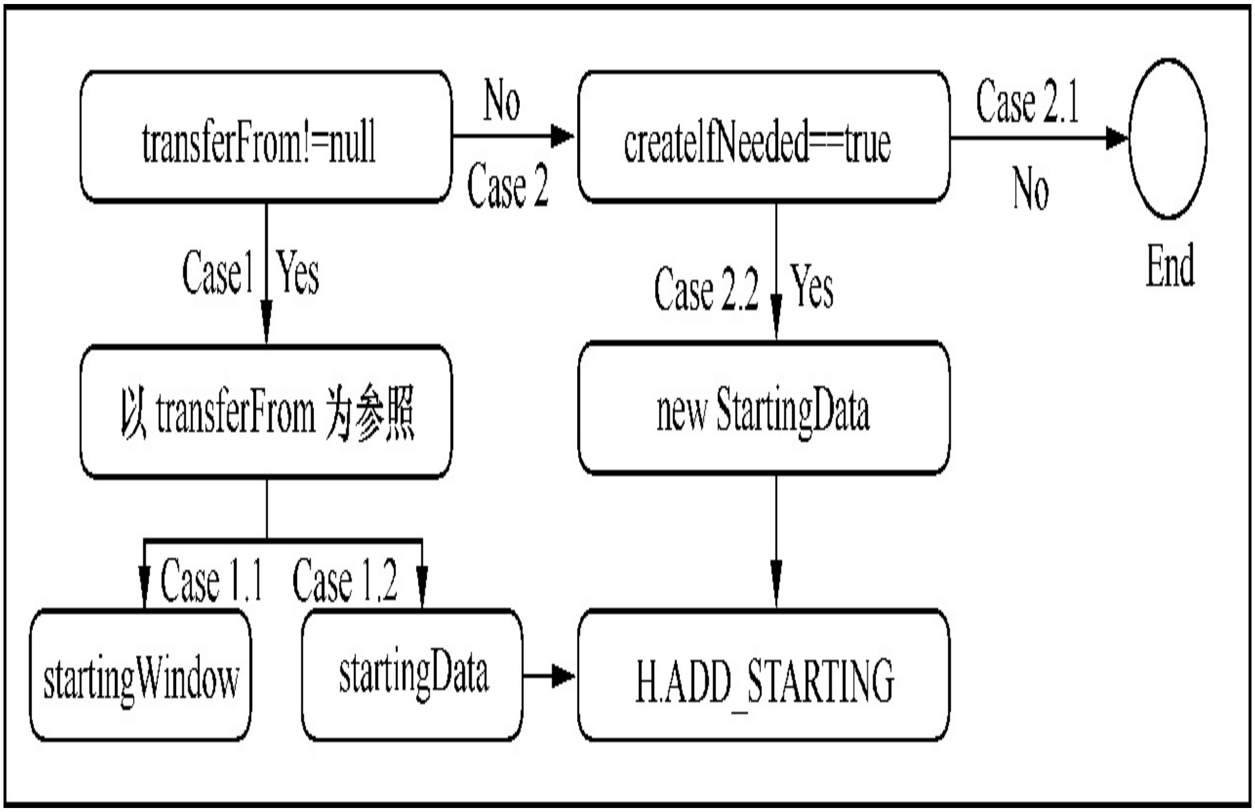

▲图10-27　创建启动窗口的处理分支

Case 1：

如果transferFrom不为空，那么我们会以此为参照物来设置启动窗口。在这种情况下同样要求transferFrom的AppWindowToken不为空。如下所示：

```
AppWindowToken ttoken = findAppWindowToken(transferFrom);
```

然后又可以分为以下两种具体的case。

- Case 1.1 ttoken.startingWindow存在

startingWindow是一个WindowState，说明transferFrom的启动窗口还没有被WMS移除。在这种情况下要做的工作就是把startingWindow移交给新的Activity，包括参数的转移；从WMS中移除startingWindow；以及transferFrom本身状态的清理（因为此时这个启动窗口已经不属于它了）。另外，就是把移交后的startingWindow通过addWindowToListInOrderLocked重新添加到WMS中，并使用

performLayoutAndPlaceSurfacesLocked把它真正显示出来。

- Case 1.2 ttoken.startingData != null

如果startingWindow不存在，但是描述启动窗口的数据不为空，那么同样可以用来作为参考。不过和上面的Case相比，它最后还需要向WMS发送ADD_STARTING指令来完成启动窗口的具体创建与添加。这点和Case 2.2一样。

Case 2：

假如transferFrom为空，则意味着我们没有参照物。此时分为两种情况。

- Case 2.1 createIfNeeded==false

既然没有可参考的对象，而调用者（ActivityStack）又不同意构造一个新的窗口，那么操作中止，直接返回。

- Case 2.2 createIfNeeded==true

意味着要从头构造一个新的启动窗口。另外，这时还要先通过Activity本身的主题来判断是否适合显示启动窗口。假如设置了windowIsTranslucent，windowIsFloating或者windowShow Wallpaper（且mWallpaperTarget不为空）中的任何一种属性，那么同样中止操作。而如果一切顺利，程序会通过发送一个名为ADD_STARTING的消息来促使WMS进入下一步操作。

因为在将ADD_STARTING入栈时，使用的是sendMessageAtFrontOfQueue，所以这个消息将在下轮Message Loop时就被处理，以保证启动窗口可以及时地显示出来。WMS中处理ADD_STARTING的核心语句如下：

```
view = mPolicy.addStartingWindow(wtoken.token, sd.pkg, sd.theme,
                               sd.nonLocalizedLabel, sd.labelRes, sd.icon
```

变量mPolicy是一个WindowManagerPolicy的final对象，初始化时由PolicyManager.makeNew WindowManager()赋值。根据前面几个小节的分析，我们知道makeNewWindowManager创建的是一个

PhoneWindowManager：

```
/*frameworks/base/policy/src/com/android/internal/policy/impl
public View addStartingWindow(IBinder appToken, String packag
        CompatibilityInfo compatInfo, CharSequence nonLocaliz
        int icon, int windowFlags) {…
    try {…
        Window win = PolicyManager.makeNewWindow(context);//生
        …
        Resources r = context.getResources();
        win.setTitle(r.getText(labelRes, nonLocalizedLabel));
        win.setType( WindowManager.LayoutParams.TYPE_APPLICAT
        win.setFlags(…);//设置各种窗口标志。启动窗口是比较特殊的，比
        …
        win.setLayout(WindowManager.LayoutParams.MATCH_PARENT
                WindowManager.LayoutParams.MATCH_PARENT);/*尺
        final WindowManager.LayoutParams params = win.getAttr
        params.token = appToken;
        params.packageName = packageName;
        params.windowAnimations = win.getWindowStyle().getRes
                com.android.internal.R.styleable.Window_windo
                /*动画类型*/
        …
        params.setTitle("Starting " + packageName);
       WindowManager wm =
                   (WindowManager)context.getSystemService(Co
        View view = win.getDecorView();
        …
        wm.addView(view, params);//添加一个窗口，我们在前几个小节分
        return view.getParent() != null ? view : null;
    } catch (WindowManagerImpl.BadTokenException e) {
    } catch (RuntimeException e) {
       …
    }
    return null;
}
```

和Activity窗口类似，启动窗口也需要在“本地”建立一个Window对象，用于描述即将显示界面的外部“框架”。从上面函数可以看出，这个Window的属性如下。

- 窗口大小

宽和高都是MATCH_PARENT，所以是满屏显示（因为它是顶层父窗口）。

- 窗口类型

  毋庸置疑，就是TYPE_APPLICATION_STARTING。

- 窗口标题

  由getText(labelRes, nonLocalizedLabel)计算得到。

- 窗口标志

这是一个临时性的窗口，所以不应该是touchable或者focusable的。

和普通的Activity窗口一样，我们需要将启动窗口注册到WMS中，然后由后者在SurfaceFlinger中申请一个Surface来承载UI数据，以使窗口能真正地显示到屏幕上。代码如下：

```
wm.addView(view, params);
```

接下来的步骤就和Activity窗口的添加流程完全一致，此处不再赘述。

10.7.2 启动窗口的销毁

正常情况下，一旦应用程序的主窗口显示出来，与之相关联的启动窗口就会被销毁。另外，系统在某些特殊情况下也会考虑移除启动窗口——不论是什么原因引起的启动窗口的销毁，都会发送消息给WMS进行处理，如REMOVE_STARTING或者FINISHED_STARTING。以前者为例，其流程如图10-28所示。

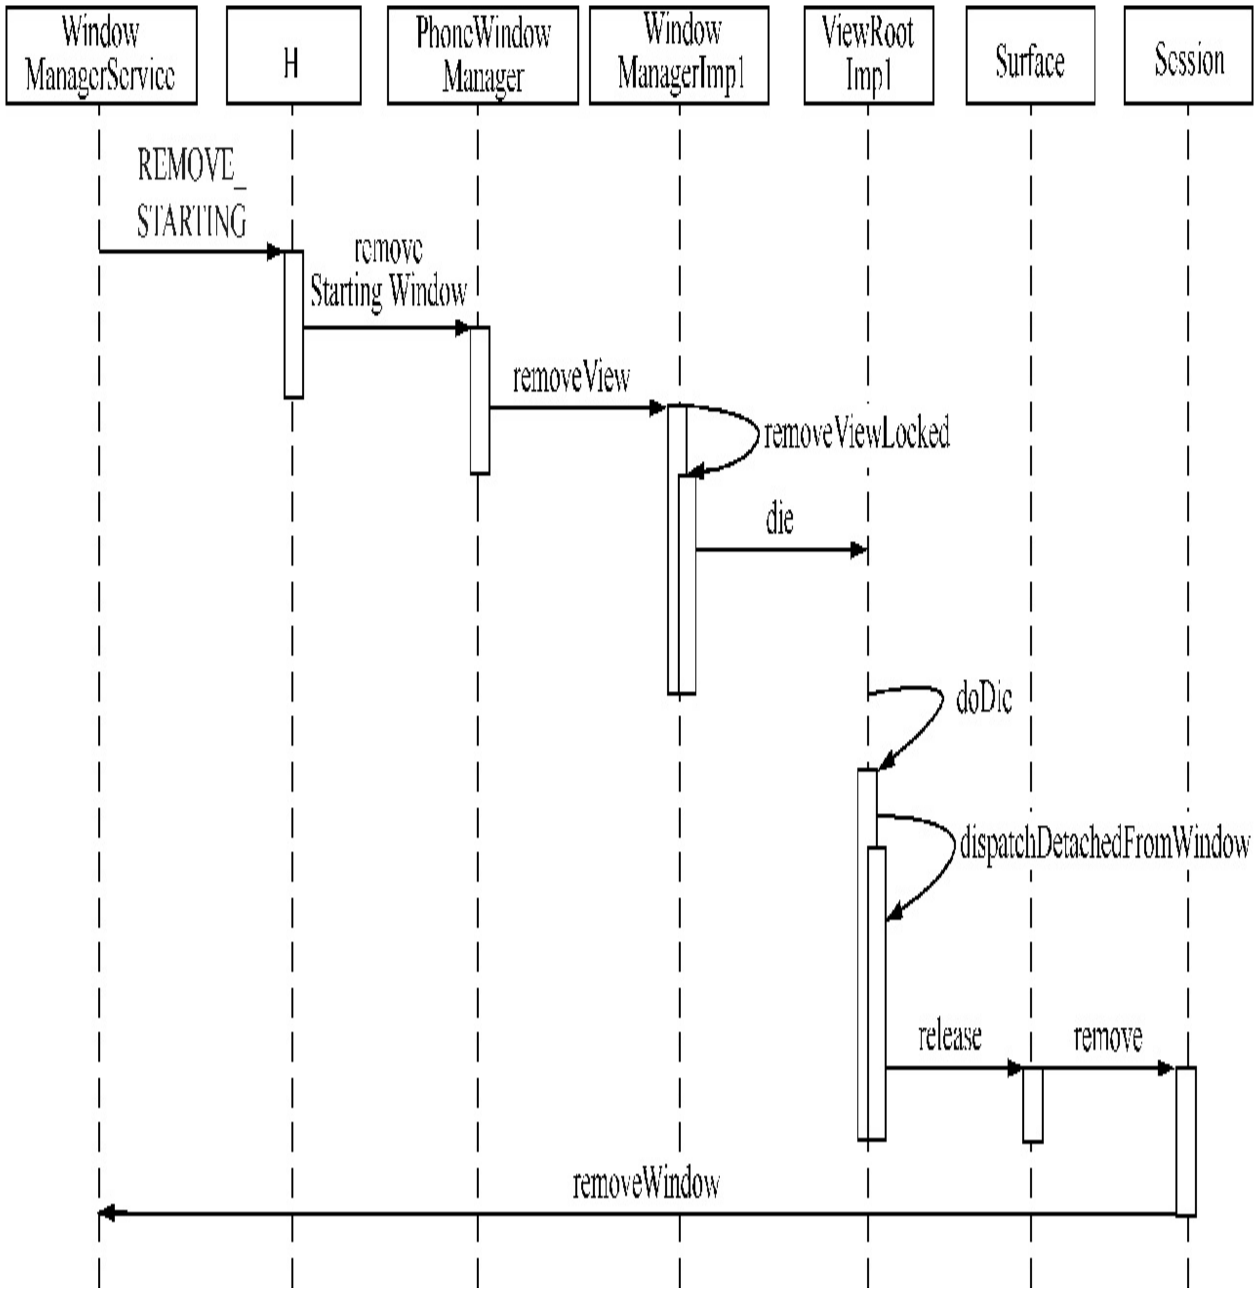

▲图10-28　移除启动窗口流程

这个流程虽然看上去比较复杂，但概括起来只有3个方面。

1．窗口的拥有者

窗口的拥有者通过WindowManagerImpl来管理它名下的所有Window。具体而言，就是mViews，mRoots和mParams 3个成员数组。启动窗口从这个角度来讲与普遍窗口并没有本质区别，只不过拥有者的身

份有差异，所以当它被移除时就自然要考虑到窗口拥有者内部信息的更新。当WMS处理REMOVE_STARTING消息时，它首先调用PhoneWindowManager.removeStarting Window，紧接着就由WindowManagerImpl来执行removeView。

清理工作分为两部分，即ViewRootImpl.die和removeItem。

函数die带有一个boolean参数，表示是否马上处理die事件。如果回答是肯定的（true），那么直接调用doDie；否则将一个MSG_DIE消息入栈，排队处理：

```
/*frameworks/base/core/java/android/view/ViewRootImpl.java*/
void doDie() {
     checkThread();//当前线程是否可以操作UI元素
     synchronized (this) {
       if (mAdded) {
           dispatchDetachedFromWindow();
       }
       …
       mAdded = false;
    }
 }
```

Android系统中的UI刷新遵循一条规则，即只有创建UI元素的线程才能使用它。因而在做应用程序开发时，工作线程通常需要向主线程发送消息来间接完成刷新界面的操作。这里的情况也类似，checkThread会首先检查执行doDie的线程是否和创建ViewRootImpl的线程一致。

成员变量mAdded表示ViewRootImpl当前是否有关联的View。只有当true的时候，我们才需要进一步调用dispatchDetachedFromWindow，并将此变量置为false。

2．Surface

一旦窗口被移除，那么与之相对应的数据缓冲区也就没有存在的必要了。在dispatchDetached FromWindow中，会通过mSurface.release来释放这个窗口的Surface。

3．WMS中的WindowState

WindowState是WMS内部用于记录窗口状态的，因而移除启动窗口同样要更新这一信息。在dispatchDetachedFromWindow中，会通过sWindowSession.remove(mWindow)来调用WMS的删除窗口服务。变量sWindowSession是一个IWindowSession，服务端由Session.java实现，这个“中介”将直接调用WMS的removeWindow来执行具体操作，并在最后通过performLayout AndPlaceSurfacesLocked来调整当前系统的窗口界面，以使这一变化能真实地体现在终端屏幕之上。

以上这3个方面所涉及的代码逻辑与启动窗口的添加流程类似，读者可以自行详细分析其中的源码实现。

10.8　窗口动画

上一小节我们理解了启动窗口的显示与消失过程，但这还不是Activity窗口切换的全部。事实上当从Activity1过渡到Activity2的过程中，还可能涉及窗口动画。

窗口的切换动画可以分为两类：

- 进入动画（Enter Animation）；
- 退出动画（Exit Animation）。

理论上这些动画是可以定制的。比如可以设计一种飞入效果，让新启动的Activity窗口从屏幕左边以一定的速率进入用户视角；或者以尺寸渐变的形式由小而大地显示出新窗口。

和启动窗口不同的是，窗口动画并不需要创建额外的Window——为了理解其中的缘由，我们首先要清楚动画的实现原理。Animation的定义是：

“Animation is the rapid display of a sequence of images to create an illusion of movement”。

动画的本质是通过连续不断地显示若干图像来产生“动”起来的效果。举个前面的“窗口飞入动画”的例子，就是在一定的时间段内，以恰当的速率（研究表明，图像的更新速率必须达到12帧/秒以上，才能让人眼和大脑觉得这是一个平滑的动画）每隔若干时间在屏幕上更新一次这个窗口的最新位置。

“尺寸渐变”的效果也类似。唯一的区别在于前者是位置的变换，而这里则指“尺寸”的变化；同理，还会有其他属性变更所引起的动画特效。从线性数学的角度来讲，包括：

- 平移（Translate）；
- 旋转（Rotate）；
- 缩放（Scale）；
- 透明度（Alpha）。

很显然，这几种属性的变化并不是孤立的，它们可以被组合起来使用。比如在“飞入”的同时还能搭配“尺寸”渐变，或者旋转——不论怎样的组合方式，我们都可以统一用Matirx运算来实现。因为从技术实现的角度来讲，Matrix是动画的核心。

理解了以上基础知识，我们应该就明白为什么不需要额外的窗口来执行动画过程了。任何类型的动画效果，都可以分解为“窗口本身”+“特定时间点的Matrix变换矩阵”+“一个代表Alpha变换的float类型值”。

10.8.1　窗口动画类型

随着Android版本的不断更迭换代，加入的窗口动画类型也越来越多，整个逻辑架构显得比较凌乱。因而我们有必要先对它们进行分类与归整。最新版本的系统至少有如下3种核心窗口动画管理者：

- AppWindowAnimator；
- WindowStateAnimator；
- ScreenRotationAnimation。

从源码的角度来看，它们又分属于表10-13所示的对象（Owner）中。

表10-13　Animator

Animator Object	Owner
AppWindowAnimator	AppWindowToken中的成员变量mAppAnimator即代表了此应用程序所属的AppWindowAnimator动画
WindowStateAnimator	WindowManagerService记录了所有窗口的WindowState，其中WindowState.mWinAnimator是一个WindowStateAnimator对象。它和上面的

	AppWindowAnimator一样都是可以由应用开发人员自行定制的，后续小节有详细分析
ScreenRotationAnimation	屏幕旋转动画。WindowManagerService中的mAnimator是一个WindowAnimator类型的对象，其中WindowAnimator.mScreenRotationAnimation即屏幕旋转动画

接下来主要以AppWindowAnimator和WindowStateAnimator的分析为主，其他类型的动画原理也是一样的，读者可以作为练习自行阅读。

这两种类型的动画还可以进一步细分成若干子类型，如表10-14和表10-15所示。

表10-14　与Window相关的动画类型（定义在WindowManagerPolicy.java中）

Transitions	Description
TRANSIT_ENTER	Window被添加到屏幕上
TRANSIT_EXIT	Window从屏幕移除
TRANSIT_SHOW	Window变为可见
TRANSIT_HIDE	Window变为不可见
TRANSIT_PREVIEW_DONE	Starting window退出，以显示真正的窗口

表10-15　与App Window（Transition）相关的动画类型（定义在AppTransition.java中）

Transitions	Description
TRANSIT_UNSET	未初始化
TRANSIT_NONE	没有设置动画
TRANSIT_ACTIVITY_OPEN	一个新的Activity被同一个task中的另一Activity打开，此时的Window动画就应该是这种类型的（属于ENTER动画的一种）
TRANSIT_ACTIVITY_CLOSE	处于栈顶的Activity关闭后，将重新显示其下的Activity，此时窗口动画以这种类型显示（属于EXIT动画的一种）
TRANSIT_TASK_OPEN	Activity将在新的task中被打开（属于ENTER动画）
TRANSIT_TASK_CLOSE	Activity关闭后，将重新显示前一个Activity（不同的task栈）

虽然细分的种类比较多，但它们都可以理解为进入或者退出动画的一种。比如：

```
public static final int TRANSIT_ACTIVITY_OPEN = 6 | TRANSIT_E
public static final int TRANSIT_ACTIVITY_CLOSE = 7 | TRANSIT_
public static final int TRANSIT_TASK_OPEN = 8 | TRANSIT_ENTER
```

```
    public static final int TRANSIT_TASK_CLOSE = 9 | TRANSIT_EXIT
```

TRANSIT_ENTER_MASK和TRANSIT_EXIT_MASK分别取值0x1000和0x2000，这样可以有足够的位数来容纳各种动画类型；同时，也可以通过某种TRANSIT是否带有这两种MASK来鉴别它们所属的是进入或者退出动画。

上述第一个表中的TRANSIT_ENTER，TRANSIT_EXIT，TRANSIT_SHOW，TRANSIT_HIDE和TRANSIT_PREVIEW_DONE五种动画类型是与窗口相关的，由WindowStateAnimator来管理；剩余部分则由AppWindowAnimator来管理，我们将在接下来的小节中分别解释。

10.8.2　动画流程跟踪——WindowStateAnimator

我们知道，当一个新的Activity启动时，它需要间接调用WMS提供的relayoutWindow来申请一个Window：

```
    /*frameworks/base/services/java/com/android/server/wm/WindowM
public int relayoutWindow(…int viewVisibility…){…
    if (toBeDisplayed) {//即将显示
                    if (win.isDrawnLw() && okToDisplay()) {
                        winAnimator.applyEnterAnimationLocked();
                    }
     …
```

需要注意的是，relayoutWindow既可用于申请Window，同时还可移除一个Window，这取决于函数入参viewVisibility的具体值。对于窗口进入动画，viewVisibility的值必然是View.VISIBLE，即客户请求显示界面。

变量toBeDisplayed用于表示窗口是否需要显示，它通过isVisibleLw来判断。如果当前窗口还没有Surface，或者正在进行退出动画（随后便会移除Surface），或者它的app token被隐藏，那么isVisibleLw都会返回false。另外，我们还需要判断窗口是否有合法的Surface、是否已经完整地绘制过UI，而且当前屏幕处于okToDisplay的状态——只有这些条件都满足，才能最终开始执行进入动画，即调用winAnimator.applyEnterAnimationLocked()。

WindowStateAnimator是从旧版本中的WindowState分离出来的，专门用于动画流程的跟踪以及和Surface相关的若干操作：

```
/*frameworks/base/services/java/com/android/server/wm/WindowState
void applyEnterAnimationLocked() {
        final int transit;
        if (mEnterAnimationPending) {
            mEnterAnimationPending = false;
            transit = WindowManagerPolicy.TRANSIT_ENTER;
        } else {
            transit = WindowManagerPolicy.TRANSIT_SHOW;
        }
        applyAnimationLocked(transit, true);
        …
    }
```

从上面这个函数的实现可以看出，进入动画分为两种——TRANSIT_ENTER和TRANSIT_SHOW。前者是当mEnterAnimationPending为true时执行的，表示窗口处于“从无到有”的临界点。具体来讲是:

- addWindow

  此时Window刚被添加，当然是“从无到有”。

- oldVisibility == View.GONE

  之前的状态是GONE，现在变为VISIBLE，也可以认为是“从无到有”。

假如mEnterAnimationPending为true，程序执行TRANSIT_ENTER动画，否则就只是TRANSIT_SHOW。我们来看看它们有什么区别:

```
    boolean applyAnimationLocked(int transit, boolean isEntrance)
       if (mLocalAnimating && mAnimationIsEntrance == isEntrance)
          //如果当前正在执行的动画类型与isEntrance是一致的，那么系统就不重
          return true;
       }
       if (mService.okToDisplay()) {//当前屏幕处于可以显示的状态
          int anim = mPolicy.selectAnimationLw(mWin, transit);//选
          int attr = -1;
          Animation a = null;
          if (anim != 0) {
              a = AnimationUtils.loadAnimation(mContext, anim);//
          } else {//anim为0的情况下，使用默认动画资源
              switch (transit) {
                  case WindowManagerPolicy.TRANSIT_ENTER:
                     attr = com.android.internal.R.styleable.Wind
```

```
                    terAnimation;
                    break;
                case WindowManagerPolicy.TRANSIT_EXIT:
                    attr = com.android.internal.R.styleable.Wind
                    Animation;
                    break;
                …
            }
            if (attr >= 0) {
                a = mService.mAppTransition.loadAnimation(mWin.

            }
        }
        if (a != null) {
            …
            setAnimation(a);
            mAnimationIsEntrance = isEntrance;
        }
    } else {
        clearAnimation();//屏幕当前状态不适合显示，清除动画
    }
    return mAnimation != null;
}
```

上述代码段分为如下几个步骤，如图10-29所示。

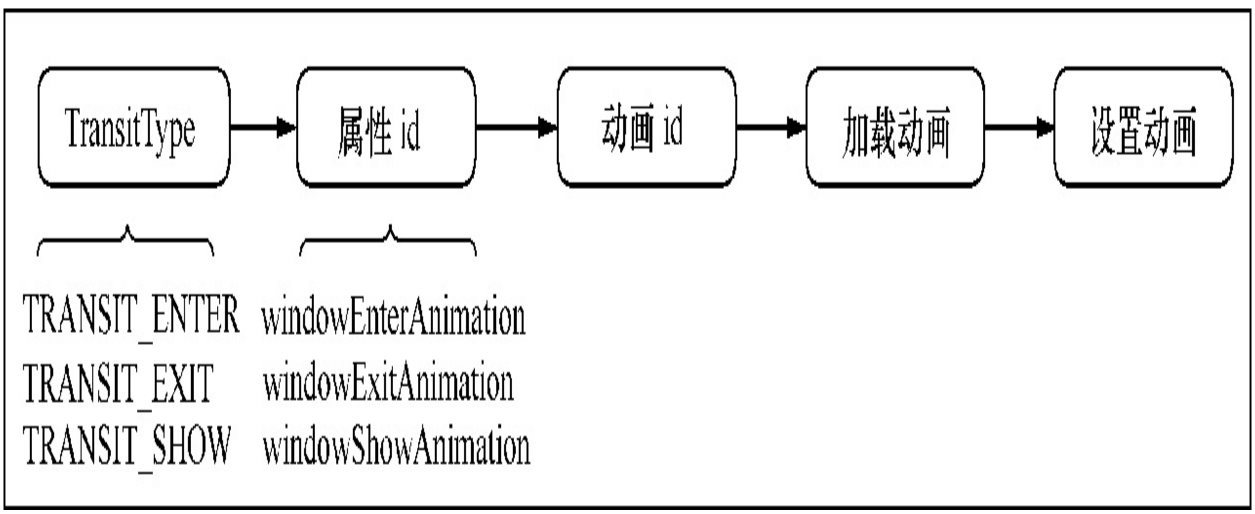

▲图10-29　动画的选择过程

1．获取对应的动画id

特殊类型的窗口如StatusBar和NavigationBar，它们的进入/退出

动画和普通窗口是有差别的——具体而言，它们将由selectAnimationLw来选择对应的动画资源id；否则（也就是上述代码段中anim为0的部分）就需要先根据transit类型来获取对应的属性id，再进一步选择实际的动画效果id值。如TRANSIT_ENTER对应的属性id值为：

```
com.android.internal.R.styleable.WindowAnimation_windowEnterAnima
```

而TRANSIT_EXIT对应的属性id值为：

```
com.android.internal.R.styleable.WindowAnimation_windowExitAnimat
```

这样程序通过windowEnterAnimation和windowExitAnimation这两个id属性的具体配置就可以获取动画id了。

2. 加载动画

加载动画使用的接口是AnimationUtils.loadAnimation。需要提醒大家的是，selectAnimationLw返回的值就是动画id，所以可以直接通过AnimationUtils.loadAnimation来加载。其他情况下首先需要得到的是attr值，因而调用的接口是mService.mAppTransition.loadAnimation——不过可以猜测到后者的函数内部也一定会再调用AnimationUtils.loadAnimation。变量mService就是Window ManagerService自身，而mAppTransition是一个AppTransition对象。如下所示：

```
Animation loadAnimation(WindowManager.LayoutParams lp, int an
    int anim = 0;
    Context context = mContext;
    if (animAttr >= 0) {
        AttributeCache.Entry ent = getCachedAnimations(lp);
        if (ent != null) {
            context = ent.context;
            anim = ent.array.getResourceId(animAttr, 0);//通过
        }
    }
    if (anim != 0) {
        return AnimationUtils.loadAnimation(context, anim);//
    }
    return null;
}
```

既然是通过属性id来动态获取动画id，而不是由系统直接指定一个默认值，就意味着我们可以根据自己的需求来定制动画效果。基于Activity的应用程序可以在自定义的theme中提供窗口动画，或者直接使用系统中预安装的主题动画。

下面是SystemUI应用中的一个实例：

```
<style name="Animation.RecentPanel">
    <item name="android:windowEnterAnimation">@*android:anim/grow
    <item name="android:windowExitAnimation">@*android:anim/shrin
</style>
```

上述windowEnterAnimation指定的是名为“grow_fade_in_from_bottom”的动画，也同样由xml文件来描述，可以参照本书应用篇中对Android资源管理的分析。

我们将“grow_fade_in_from_bottom”的部分核心语句摘录如下：

```
<set xmlns:android="http://schemas.android.com/apk/res/android" a
<scale android:interpolator="@interpolator/decelerate_quint"
               android:fromXScale="0.9" android:toXScale="1.0"
     android:fromYScale="0.9" android:toYScale="1.0"
     android:pivotX="50%" android:pivotY="100%"
     android:duration="@android:integer/config_activityDefaultDur
<alpha      android:interpolator="@interpolator/decelerate_cubic"
            android:fromAlpha="0.0" android:toAlpha="1.0"
            android:duration="@android:integer/config_activitySho
</set>
```

从名称可以看出来，这个进入动画希望实现的效果是“grow”+“fade in”+“from bottom”。分解到实现层面，就是由scale与alpha两个属性组成的动画。上面xml文件中的各属性解释如下：

interpolator：动画的“变化率”。打个比方，如果规定在10秒内跑完100米，那么实际在执行时既可以匀速地跑（即10米/秒）；也可以一开始跑快点，然后慢慢减速；也可以一开始跑慢点，然后慢慢加速。这些跑法都是符合“10秒内跑完100米”规定的，具体选择哪种就看实际需要了。

fromXScale/fromYScale：也就是Scale变化的“起点”，包括x和y

轴，1.0表示没有变化。

toXScale/toYScale：scale变化的“终点”，同样的1.0代表没有变化。

pivotX/pivotY：scale操作需要有一个“核心参考点”，它既可以是图形的正中心，也可以自行指定。

Duration：按照上面的例子，就是指“多长时间”跑完100米。

fromAlpha/toAlpha：alpha变化的“起点”和“终点”。

这样我们就自定义了一个窗口的“进入动画”效果，并通过“android:windowEnterAnimation”属性告知了系统。

3. 设置动画

函数applyAnimationLocked最后会通过setAnimation来将一个Animation对象设置到WindowStateAnimator中。代码如下：

```
public void setAnimation(Animation anim) {…
    mAnimating = false;
    mLocalAnimating = false;
    mAnimation = anim;//记录Animation对象
    mAnimation.restrictDuration(WindowManagerService.MAX_ANIM
    mAnimation.scaleCurrentDuration(mService.mWindowAnimation
    …
}
```

可以看到，这个函数将动画对象（Animation）保存在mAnimation成员变量中，并做初始化动作。不过需要特别注意的是，此时并没有真正执行动画效果，而只是对动画相关的各元素进行了设置——后续小节会专门介绍整个“动画”是如何在VSYNC组织下有序地“动”起来的。

10.8.3 AppWindowAnimator

当启动一个新的Activity时，AMS会根据当前的实际情况来判断是否为应用程序设置AppWindowAnimator以及动画的类型。和上一小节类似，这里的动画类型指的是TRANSIT_ACTIVITY_OPEN，TRANSIT_ACTIVITY_CLOSE等，而具体的动画实现也是可以由开发者定制

的。比如在TRANSIT_ACTIVITY_OPEN的情况下会优先考虑应用程序通过android:activityOpen EnterAnimation/ activityOpenExitAnimation属性设置的动画资源——对应的源码实现体现在ActivityStack.java中，它通过WMS提供的prepareAppTransition接口来为应用程序设置AppWindow Animation。这个动画将由该应用程序在WMS中的token，即AppWindowToken中的mAppAnimator成员变量来管理。其流程如图10-30所示。

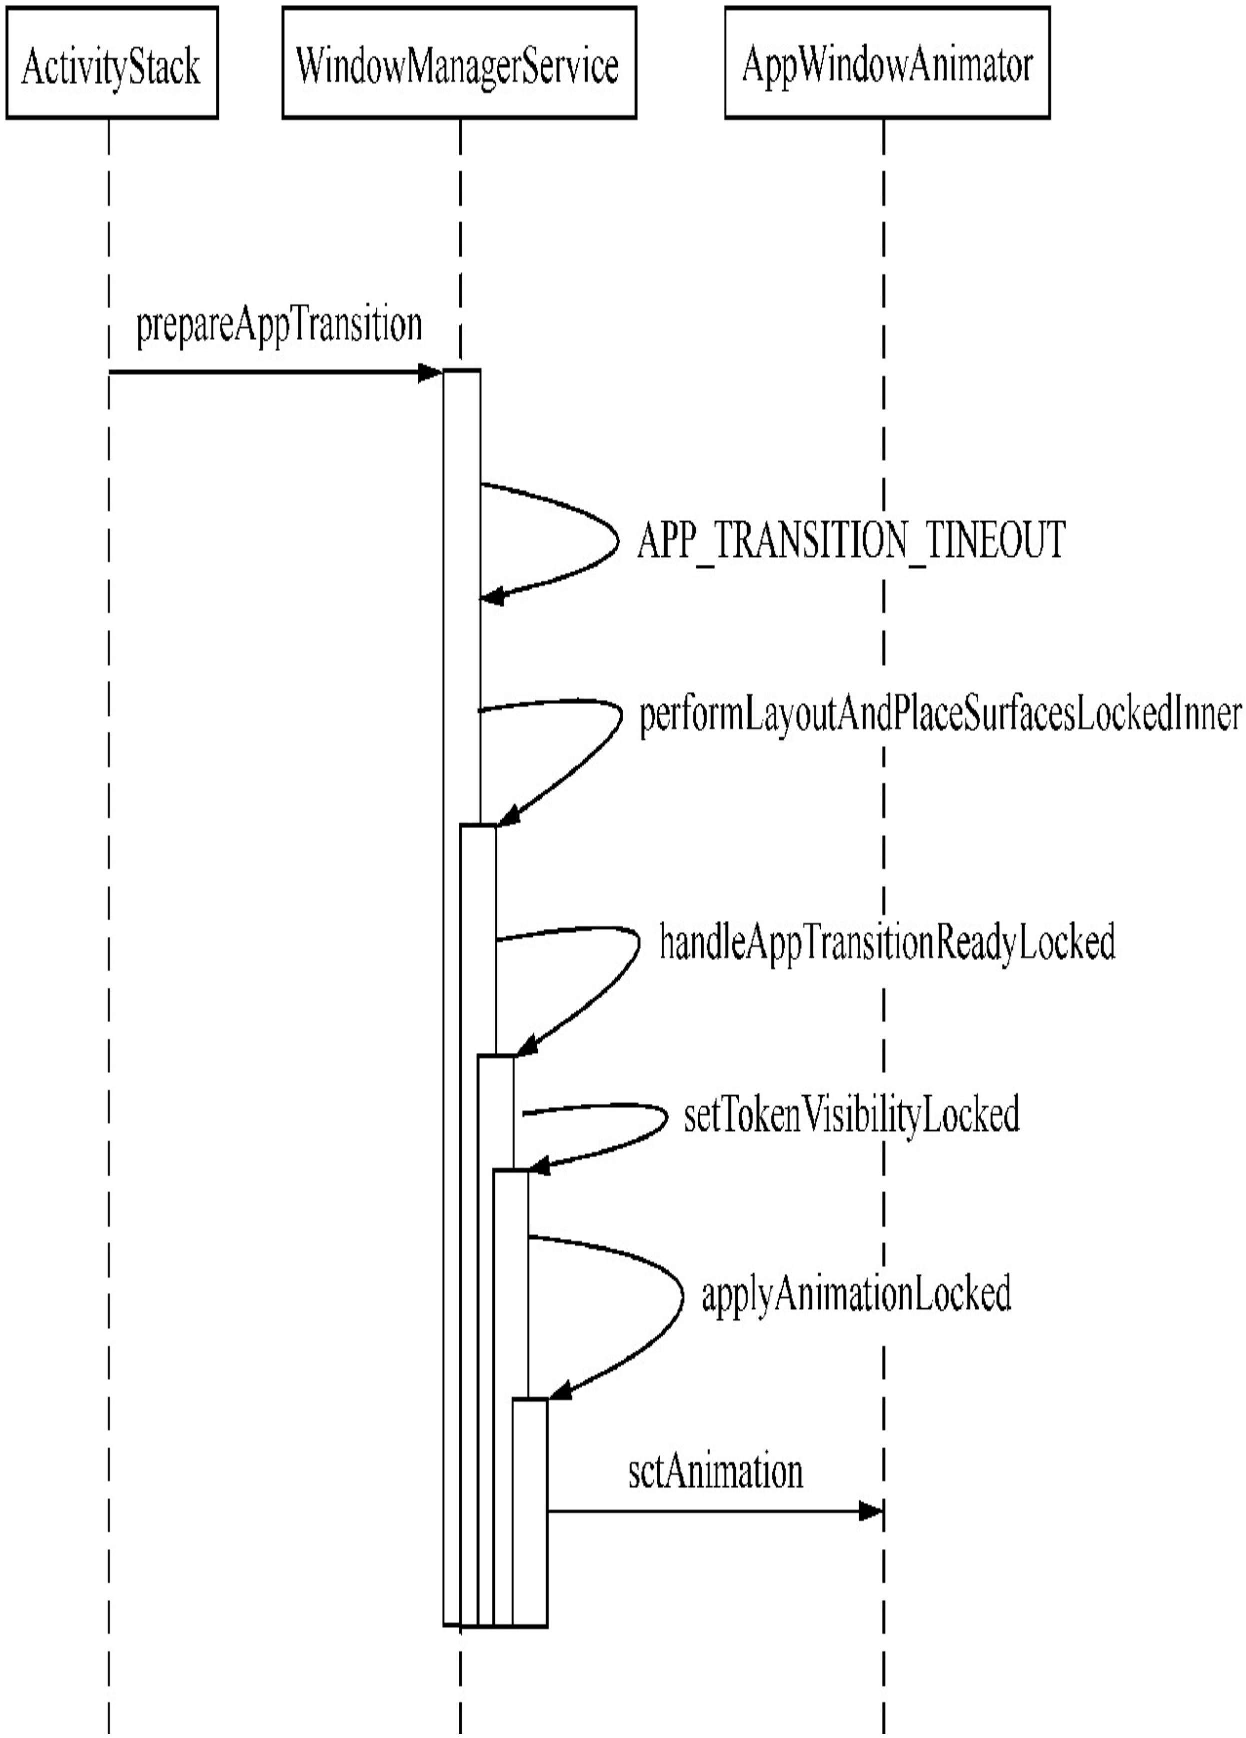
ActivityStack
WindowManagerService
AppWindowAnimator
prepareAppTransition
APP_TRANSITION_TINEOUT
performLayoutAndPlaceSurfacesLockedInner
handleAppTransitionReadyLocked
setTokenVisibilityLocked
applyAnimationLocked
sctAnimation

▲图10-30　AppWindow Animation添加流程图

我们来看看applyAnimationLocked的实现：

```
/*frameworks/base/services/java/com/android/server/wm/WindowManag
private boolean applyAnimationLocked(AppWindowToken wtoken,
          WindowManager.LayoutParams lp, int transit, boolean ent
      if (okToDisplay()) {//这个函数我们解释过很多次了，不再赘述
          DisplayInfo displayInfo = getDefaultDisplayInfoLocked()
          final int width = displayInfo.appWidth;
          final int height = displayInfo.appHeight;
          Animation a = mAppTransition.loadAnimation(lp, transit,
          //加载动画资源
          …
          atoken.mAppAnimator.setAnimation(a, width, height);//设
       } else {
          atoken.mAppAnimator.clearAnimation();
       }
       return atoken.mAppAnimator.animation != null;
    }
```

这个函数做了两件事，即：

```
mAppTransition.loadAnimation(lp, transit, enter, width, height)和
atoken.mAppAnimator.setAnimation(a, width, heigh;t)
```

窗口动画在Android各版本中改动较大，因而遗留了不少“历史痕迹”。比如对于loadAnimation这个函数，在最新的版本中衍生出了3种样式——我们在WindowStateAnimator中看到的loadAnimation和上面代码段中的loadAnimation就是同名不同参的两个函数实现，读者要特别注意辨别：

```
/*frameworks/base/services/java/com/android/server/wm/AppTransiti
     Animation loadAnimation(WindowManager.LayoutParams lp, int t
                      int appWidth, int appHeight) {
        Animation a;
        if (mNextAppTransitionType == NEXT_TRANSIT_TYPE_CUSTOM) {
        } else if (mNextAppTransitionType == NEXT_TRANSIT_TYPE_SC
        } else if (mNextAppTransitionType == NEXT_TRANSIT_TYPE_TH
               mNextAppTransitionType == NEXT_TRANSIT_TYPE_THUMBN
        } else {
            int animAttr = 0;
            switch (transit) {
                case TRANSIT_ACTIVITY_OPEN:
```

```
                animAttr = enter? WindowAnimation_activityOpe
                        : WindowAnimation_activityOpenExitAni
                break;
             …//其他transit的处理是类似的，代码省略
        }
        a = animAttr != 0 ? loadAnimation(lp, animAttr) : nul
    }
    return a;
}
```

变量mNextAppTransitionType反映了当前App Transition所属的定制类型，由ActivityOptions提供定义。包括：

- ANIM_NONE

默认值，即上述代码段中的else分支。

- ANIM_CUSTOM

在Activity中有一个名为“overridePendingTransition”的函数，应用开发者可以通过重载它来定制自己的App Transition。这个函数对应的WMS端实现是overridePendingAppTransition，此时mNextAppTransitionType就会被设置为ANIM_CUSTOM。另外，当我们通过startActivity（Intent intent, Bundle options)来启动一个新的Activity时，其中第二个参数实际上是ActivityOptions，所以也可以指定App Transition的类型（只不过通常不这样做）。

- ANIM_SCALE_UP

和上一个参数类似，在调用startActivity（Intent intent, Bundle options)时，我们可以给第二个参数指定ANIM_SCALE_UP。从名称就可以看出来，这种动画是指画面尺寸“从小而大”的一种动画效果，对应的是WMS中的overridePendingAppTransitionScaleUp实现。

- ANIM_THUMBNAIL| ANIM_THUMBNAIL_DELAYED

指定这两种ANIM的方式和前面是一致的。它们表示在启动目标Activity Window前先从某个指定位置Scale Up一幅thumbnail图像。而DELAYED则表示在此之前是否还需要一定时间的延时。

无论是上述的哪一种类型，它们的处理逻辑都是类似的，即采用适当的手段来加载各类型所指定的动画资源。比如在ANIM_SCALE_UP的情况下通过createScaleUpAnimationLocked来产生一个Animation；ANIM_THUMBNAIL和ANIM_THUMBNAIL_DELAYED则对应的是createThumbnailAnimationLocked；而ANIM_NONE则是依靠读取应用程序的属性来加载动画。

最后，这些加载的动画都会被存储到AppWindowAnimator中，以期在动画实施过程中可以被访问并得到真正的应用，详见下一小节的分析。

10.8.4　动画的执行过程

前面两个小节分析了窗口动画的各种类型、创建和设置过程，那么这些动画是如何执行起来的呢？先来思考一下，窗口动画的执行需要哪些元素的支持。

- 触发源

动画是在某段时间内的连续动作，显然每隔一段时间都需要有一个“主动”的触发事件，才能保证动画的正常执行。

- 整合所有动画

既然有这么多种类的动画存在，则意味着同一个时刻系统中很可能有超过一种的动画在执行，那么Android是如何把它们整合成最终效果的？

- 与SurfaceFlinger的接口

WMS只是窗口的管理者，并不会直接影响屏幕的界面显示。因而动画的执行过程一定需要SurfaceFlinger的支持，如图10-31所示。

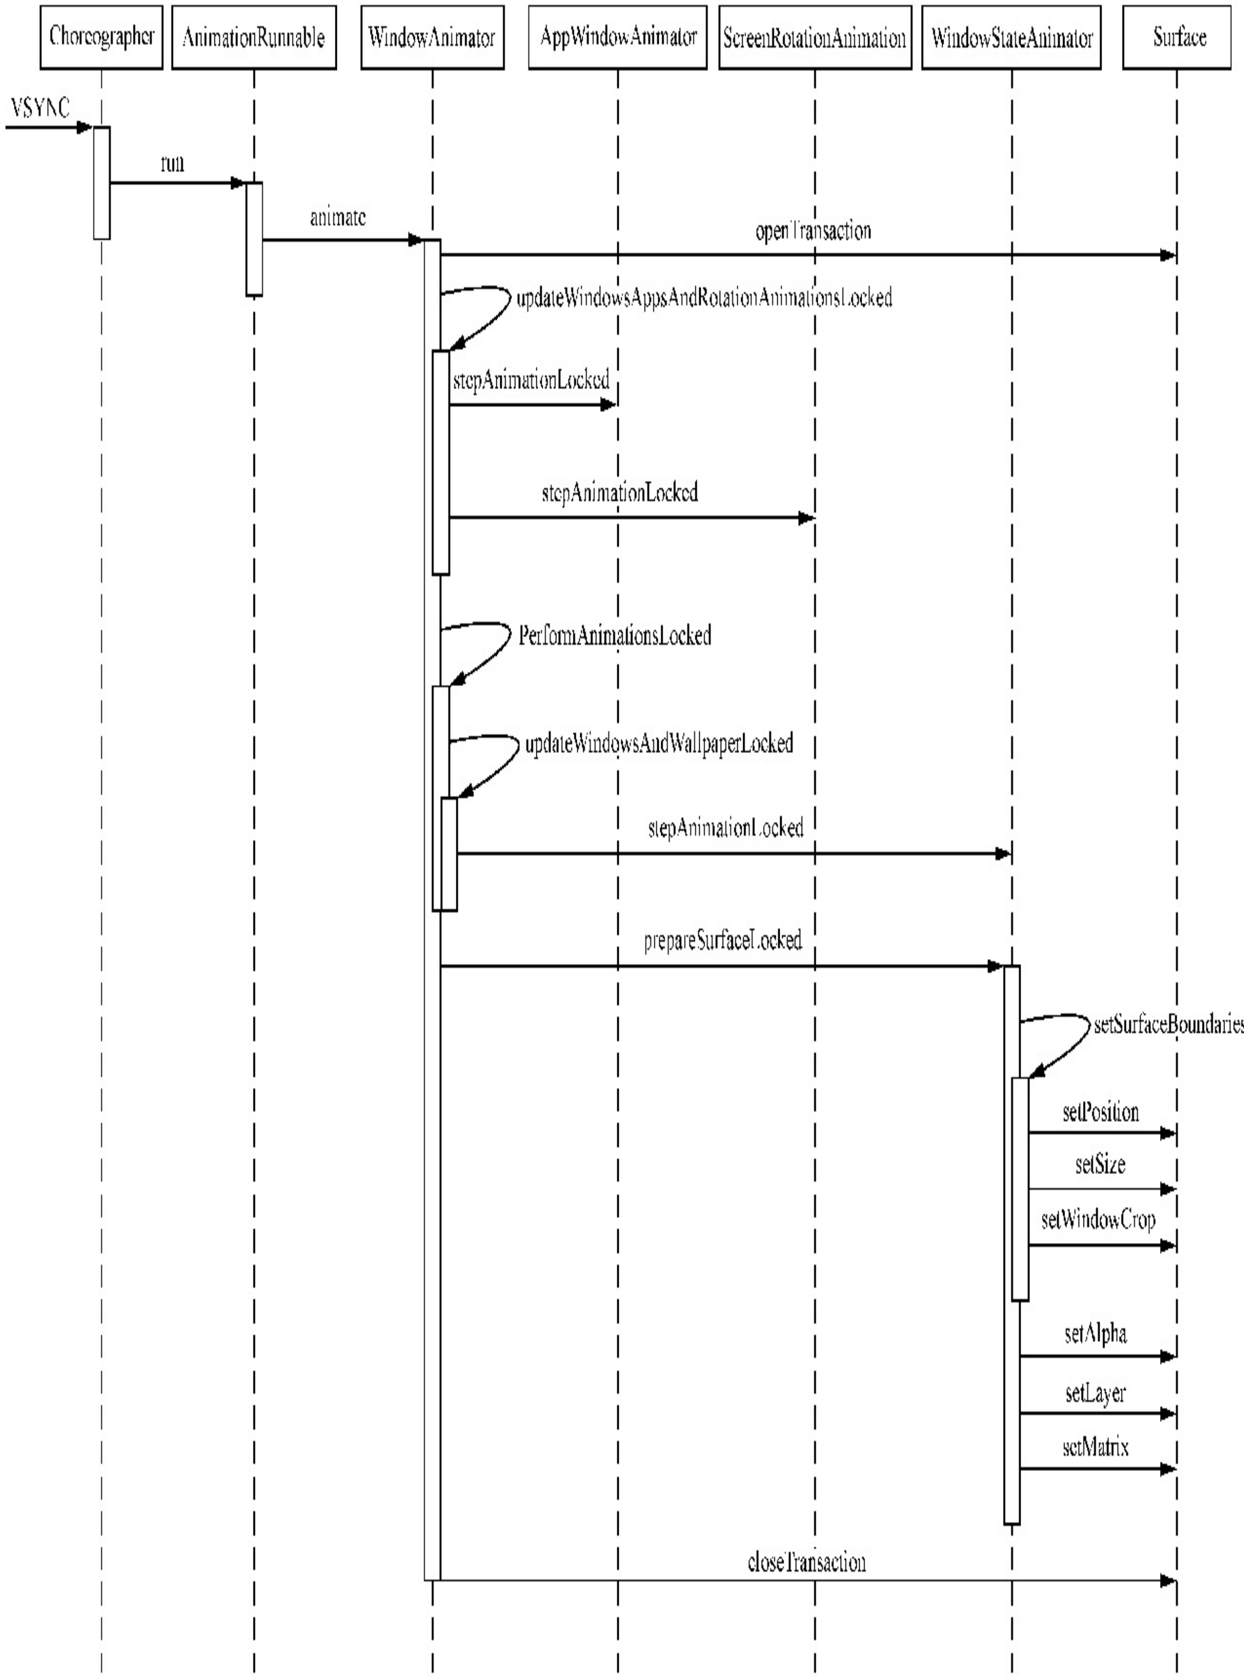
Choreographer
AnimationRunnable
WindowAnimator
AppWindowAnimator
ScreenRotationAnimation
WindowStateAnimator
Surface
VSYNC
run
animate
openTransaction
updateWindowsAppsAndRotationAnimationsLocked
stepAnimationLocked
stepAnimationLocked
PerformAnimationsLocked
updateWindowsAndWallpaperLocked
stepAnimationLocked
prepareSurfaceLocked
setSurfaceBoundaries
setPosition
setSize
setWindowCrop
setAlpha
setLayer
setMatrix
closeTransaction

▲图10-31　窗口动画执行流程图

WindowManagerService中有一个AnimationRunnable类型的成员变量mAnimationRunnable，我们以此为入口来看看它对窗口动画的组织方式。

AnimationRunnable继承自Runnable，所以重载了run()方法，我们稍后会详细分析这个函数。WMS会在需要执行动画时通过scheduleAnimationLocked来设置一个“触发源”，源代码如下：

```
void scheduleAnimationLocked() {
    if (!mAnimationScheduled) {
        mAnimationScheduled = true;
          mChoreographer.postCallback(Choreographer.CALLBACK_
                                              mAnimationRunn
    }
}
```

布尔变量mAnimationScheduled用于指示当前是否已经在schedule animation，这个值在AnimationRunnable.run中会被重新复位为false。上述代码段的核心是mChoreographer——这个变量是“线程唯一”的，即在同一线程中是单实例。根据我们在SurfaceFlinger章节中讲解的“黄油计划”，Android系统一定会以VSYNC为信号来刷新UI。那么对于应用程序（在这个场景中，WMS也是应用程序）来说，它们是如何获知VSYNC的呢？

这就是Choreographer的设计初衷。从字面来解释，它表达的是“编舞者”，所以形象地反映出了Choreographer作为“有序动作管理者”所担负的职责。关于这个类的更多解释，我们后续还会有介绍，这里暂时把它理解为“VSYNC”的接收者即可。

现在就比较清楚了，VSYNC信号就是动画的触发源。这样的设计无疑是合理而且必需的——既避免了资源的浪费，同时也保证了画面的流畅，值得借鉴。

Choreographer一方面需要接收VSYNC信号，另一方面要将这一事件转发给感兴趣的人，所以希望监听VSYNC事件的对象都需要在Choreographer中注册，如图10-32所示。

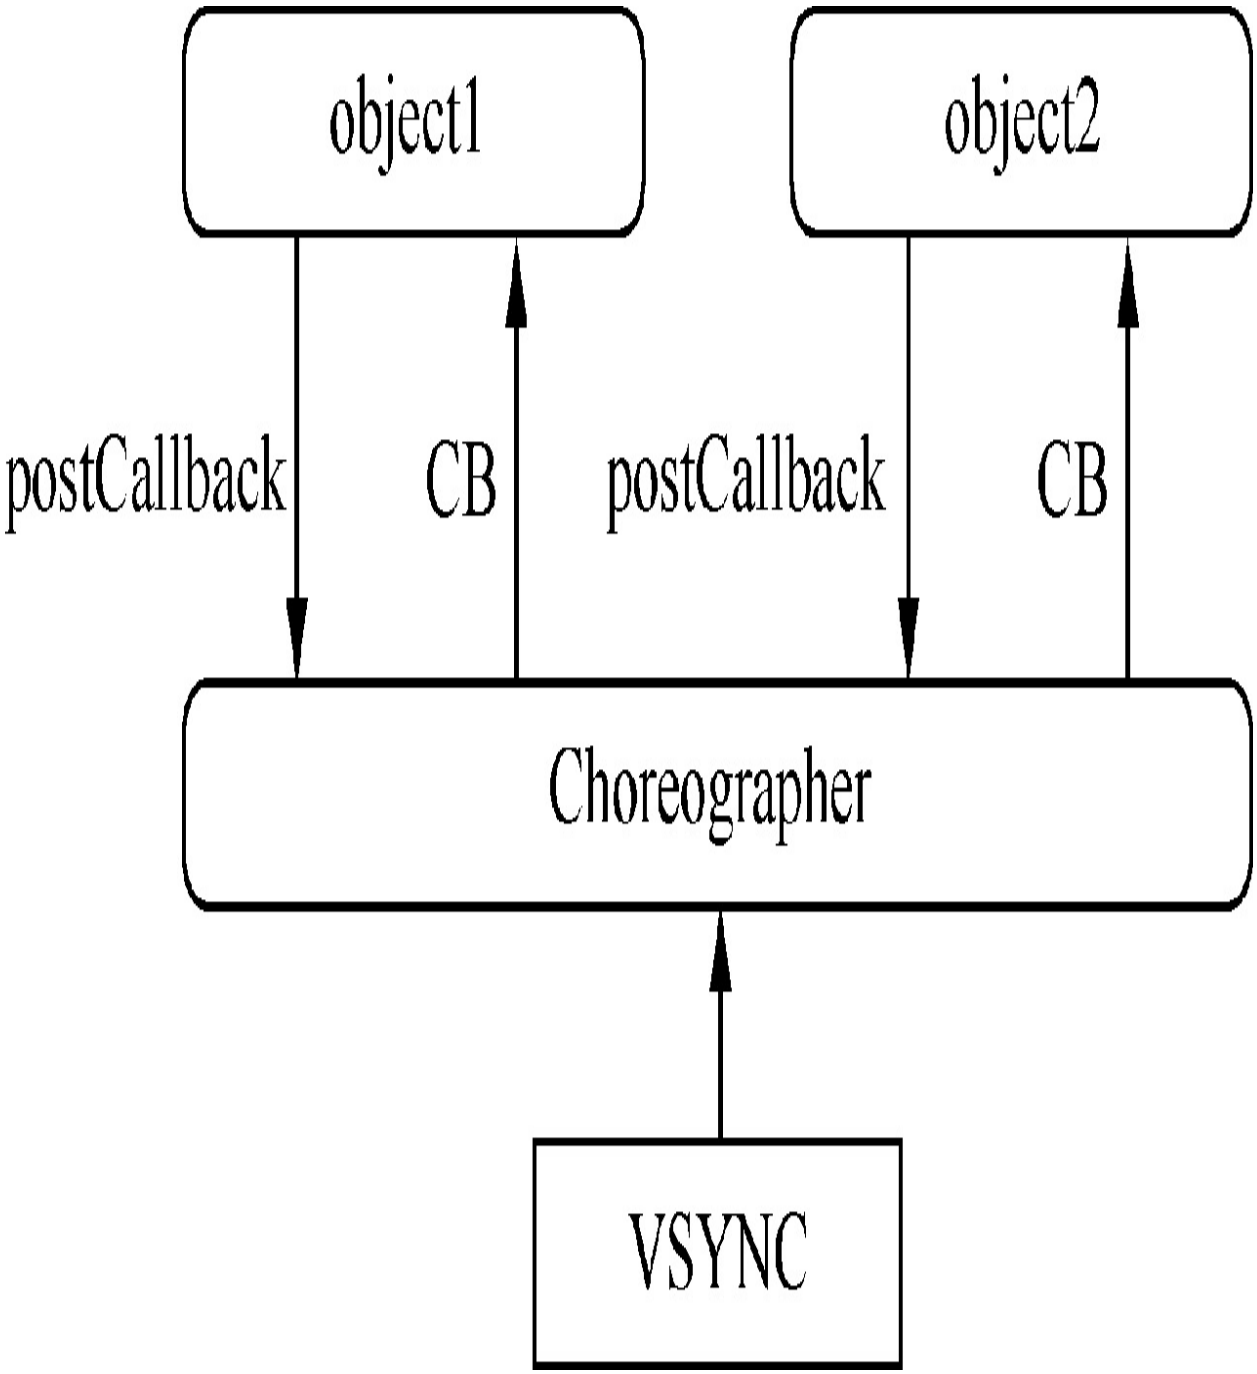

▲图10-32 Choreographer简易模型

Choreographer将所有注册者分为Input，Animation，Traversal(layout，draw)3个类别，存储在其内部的一个Queue数组（CallbackQueue[] mCallbackQueues）中。在这个场景中，动画对应的是CALLBACK_ANIMATION。

所以当VSYNC信号产生后，mAnimationRunnable中的run函数将被触发：

```
/*frameworks/base/services/java/com/android/server/wm/Window
mAnimationRunnable = new Runnable() {
       @Override
       public void run() {
           synchronized (mService.mWindowMap) {
               mService.mAnimationScheduled = false;//本次动画
               animateLocked();//各种动画的“单步执行”要开始了
           }
       }
   };
```

首先将mAnimationScheduled复位为false，代表本次的动画schedule请求已经接受。作为窗口动画的统一管理者，mAnimator由WMS在构造函数中创建。核心函数如下：

```
/*frameworks/base/services/java/com/android/server/wm/WindowA
private void animateLocked() {
   if (!mInitialized) {/*是否已经成功初始化*/
      return;
   }
   mCurrentTime = SystemClock.uptimeMillis();//当前时间
   mBulkUpdateParams = SET_ORIENTATION_CHANGE_COMPLETE;
   boolean wasAnimating = mAnimating;//记录上一次的动画状态，用于
   mAnimating = false;//先置为false
   SurfaceControl.openTransaction();/*业务开始，先本地记录下所有对
   统一提交给SurfaceFlinger。原因我们在前面小节都已经详细论述过了*/
   SurfaceControl.setAnimationTransaction();
   try {
      updateAppWindowsLocked();/*Step1. 执行App Window动画*/
      final int numDisplays = mDisplayContentsAnimators.size(
      for (int i = 0; i < numDisplays; i++) {//分别处理每个Disp
          final int displayId = mDisplayContentsAnimators.key
          DisplayContentsAnimator displayAnimator = mDisplayC
          /*Step2. 处理屏幕旋转动画*/
          final ScreenRotationAnimation screenRotationAnimati
                displayAnimator.mScreenRotationAnimation;
          if (screenRotationAnimation != null && screenRotati
                if (screenRotationAnimation.stepAnimationLock
                    mAnimating = true;//动画还未结束，下一轮还需要
             } else {…//动画结束
             }
          }
          performAnimationsLocked(displayId);/*Step3. 更新Winc
```

```
                                                    中的动画*/
            final WindowList windows = mService.getWindowListLo
            final int N = windows.size();
            for (int j = 0; j < N; j++) {
                windows.get(j).mWinAnimator.prepareSurfaceLocke
            }
        }
        …//其他类型的动画处理过程是类似的，省略代码
    } catch (RuntimeException e) {
          Log.wtf(TAG, "Unhandled exception in Window Manager",
    } finally {
          SurfaceControl.closeTransaction();/*Step5. 统一提交给Su
    }
    …
    if (mAnimating) {//接下来是否还需要再执行动画
         mService.scheduleAnimationLocked();//是的话就schedule下一
    } else if (wasAnimating) {//这是动画的最后一次“单步”
         mService.requestTraversalLocked();//要求traversal，我们将
    }
}
```

首先要说明的是，不论AppWindowAnimator，ScreenRotationAnimation或者是WindowState Animator，在每次更新动画时被调用的接口都是stepAnimationLocked。这个函数表达了“步进”的意思，即每隔特定时间点动画的最新变化。

Step1@WindowAnimator.animateLocked。这一步专门处理AppWindowAnimator中的动画，也就是AppTransition中设置的那些动画。

Step2@WindowAnimator.animateLocked。这一步专门处理屏幕旋转相关的动画（比如用户将屏幕横着看，或者竖着看）。

Step3@WindowAnimator.animateLocked。几种类型动画的处理过程是相似的，我们只选取这一步，即WindowStateAnimator动画的操作流程来做重点分析。

函数performAnimationsLocked很简单，它分别调用了updateWindowsLocked和updateWallpaperLocked（值得一提的是，在前几个Android系统版本中，这两个函数其实统称为updateWindowsAndWallpaperLocked——这应该也是历史遗留下来的产物，使得取名和逻辑显得稍微有点杂乱。但在最新版本中，这些混乱被

慢慢纠正过来了）。

来看看updateWindowsLocked的实现：

```
private void updateWindowsLocked(final int displayId) {
   ++mAnimTransactionSequence;
   final WindowList windows = mService.getWindowListLocked(di
   …
   for (int i = windows.size() - 1; i >= 0; i--) {//逐个处理所有
       WindowState win = windows.get(i);
       WindowStateAnimator winAnimator = win.mWinAnimator;
       final int flags = winAnimator.mAttrFlags;
       if (winAnimator.mSurfaceControl != null) {
           final boolean wasAnimating = winAnimator.mWasAnima
           final boolean nowAnimating = winAnimator.stepAnima
           …
```

我们并不知道系统中当前需要执行“动画步进”的WindowStateAnimator有多少。换句话说，目前的源码实现中没有把它们单独列出来管理。所以上述代码段通过循环遍历mWindows中的所有WindowStateAnimator，再通过stepAnimationLocked来由各对象自行决定是否进行动画（并不是每个WindowStateAnimator都有动画），以及如何进行动画。

整个函数虽然很长，不过最核心的语句只有一句，即：

```
winAnimator.stepAnimationLocked(mCurrentTime);
```

执行此WindowStateAnimator的“单步”动画：

```
/*frameworks/base/services/java/com/android/server/wm/WindowState
    boolean stepAnimationLocked(long currentTime) {
        mWasAnimating = mAnimating;//先保存上一次的状态，供WMS比较使用
        if (mService.okToDisplay()) {//屏幕是否允许显示
           if (mWin.isDrawnLw() &&mAnimation != null) {…
               if (!mLocalAnimating) {//第一次step这个动画，需要做些初
                 mAnimation.initialize(mWin.mFrame.width(), mWin.
                                       mAnimDw, mAnimDh);//动画初始
                 …
                 mAnimation.setStartTime(currentTime);//设置当前时间
                  mLocalAnimating = true;//已经执行过一次且初始化完成，
                  mAnimating = true;//当前正在执行动画
                }
                if ((mAnimation != null) && mLocalAnimating) {
```

```
                if (stepAnimation(currentTime)) {//计算当前的动
                    return true;//true表示动画还没结束，因而直接返
                }
            }
        }
        …
    } else if (mAnimation != null) {
        mAnimating = true;
    }
    /*一旦执行到这里，说明当前这个动画结束了，或者有其他异常*/
    if (!mAnimating && !mLocalAnimating) {/*当前不在动画，且没有
        return false;
    }
    /**以下是清理工作，省略**/
    …
    return false;//false表示动画结束
}
```

这个函数中涉及几个命名相近的变量，我们先做下集中的比较。

boolean mLocalAnimating：用于指示一个动画的第一次step。当我们设置了一个新的动画后，这个变量是false；而一旦成功地执行了一次step后，这个值就是true了。专门设计这个变量的原因是第一次执行动画时有额外的步骤要执行。比如给Animation初始化（mAnimation.initialize），设置起始时间（mAnimation.setStartTime）等。

boolean mAnimating：当前正在执行动画中。

boolean mWasAnimating：记录上一次的mAnimating，这个变量会与其他条件一起作为执行动画的参考值。

boolean mHasLocalTransformation：WindowStateAnimator在computeShownFrameLocked时，需要考虑到3种Transformation，即selfTransformation，attachedTransformation和appTransformation。其中第一个是由mHasTransformation变量决定的；其余两个则代表了此Window所依附窗口所带的Transformation，以及应用程序本身所设置的Transformation。

假如是第一次step动画，即mLocalAnimating为false，那么需要先给Animation设置尺寸大小和开始时间等参数。要特别注意的是，并不是每个WindowStateAnimator当前都有动画在执行，因而需要判断

mAnimation是否可用。只有在mAnimation!=null且mLocalAnimating为true的情况下，才能调用stepAnimation来计算动画状态。这个函数的返回结果代表当前动画是否已经完成——true说明没有完成，因而还需下一次的step，这时就可以直接返回；false表示当前的动画已经结束了，此时还要做一些清理收尾工作。

最后来看看stepAnimation是如何执行一次“单步”的：

```
private boolean stepAnimation(long currentTime) {
    if ((mAnimation == null) || !mLocalAnimating) {//没有动画对
        return false;
    }
    mTransformation.clear();//先清空
    final boolean more = mAnimation.getTransformation(current
    return more;
}
```

本节的开头我们曾概括了动画的4个要素，即缩放、平移、旋转和透明度。前三者由一个矩阵Matrix表示，最后一项则由float变量表示，它们都封装在同一个类中，即Transformation。而Animation是对动画本身的描述，如起点、终点、时长、速率等属性。这两个类是动画的核心，而且一个是“静态”的描述，另一个则是“动态”的计算。上面的stepAnimation，首先判断动画是否合法，即mAnimation必须可用，而且已经正确初始化。然后对Transformation进行清空，这是因为随后的getTransformation将直接根据当前的时间和Animation设置的起始时间计算得出一个新的变换值，并不需要依赖上一次的结果；同时，这个函数返回的值more指示了动画是否已经结束，通常就是指定的时间已经到了或者动画的最终效果已经完成。有兴趣的读者可以自行分析下这个函数的实现。

Step4@WindowAnimator.animateLocked。经过上述几种动画的“步进”计算，才只完成了WMS中的状态更新。或者说，此时用户还看不到“动画”效果。要真正将动画反映到屏幕上，就必须借助于SurfaceFlinger了。在“通知”SurfaceFlinger之前，WMS还要对Surface做一些准备工作，即prepareSurfaceLocked。

这个函数的任务有两个。

- 准备好Surface的更新数据

Surface是客户端（Java）与SurfaceFlinger间的中介，或者说是“业务的载体”。当我们需要对Surface进行批量修改时，通常是先调用Surface.openTransaction表示业务开始，随后调用Surface提供的接口进行设置，最后才是通过Surface.closeTransaction来关闭业务，并将更新信息统一传递给SurfaceFlinger。

经过前面各种类型动画的“步进”计算，WMS中的各状态已经得到了更新。这时我们就可以基于这些最新的状态来准备发送给Surface的“数据包”了，这是由computeShownFrameLocked来完成的。

- 将上一步计算出的“数据包”逐一设置到Surface对象中

动画类型的不同以及每次动画步进产生的状态有差异，导致需要设置到Surface的内容也可能有变化。具体分为两部分：

- setSurfaceBoundaries

处理Surface尺寸大小、位置相关的更新，包括Surface.setPosition、Surface.setSize和setWindowCrop等。

- setAlpha，setLayer和setMatrix等属性的更新。

Step5@WindowAnimator.animateLocked。为了使Surface中的信息生效，最后我们要通过closeTransaction来关闭业务，此时Surface中的所有更新就会传递给SurfaceFlinger，后者会在下一次的界面合成中将这些变化写入framebuffer中，于是用户就可以看到最终的动画“步进”效果了。

假如mAnimating为true，表示动画还将继续进行，因而我们接着调用scheduleAnimationLocked来安排下一次的“触发源”；如果mAnimating为false，且wasAnimating为true，此时就是动画结束前的最后一次step（因为wasAnimating记录的是上一次的mAnimating，这种情况下说明mAnimating在上一次时为true，本次则变为false，所以是最后一次），我们需要通过requestTraversalLocked来发出一个DO_TRAVERSAL消息，随后performLayoutAndPlaceSurfaces Locked会再次被调用。

第11章 让你的界面炫彩起来的GUI系统——View体系

我们在前两个章节已经深入分析了Android中GUI系统的底层支撑框架，即SurfaceFlinger和WMS两个系统服务的内部原理。但是从终端用户的角度来讲，这两者都不是他们最关心的。因为真正与用户产生直接联系的，是本章节要阐述的View体系——几乎所有APK应用程序的UI界面都是由它来描述的。

11.1 应用程序中的View框架

应用程序中的View框架如图11-1所示。

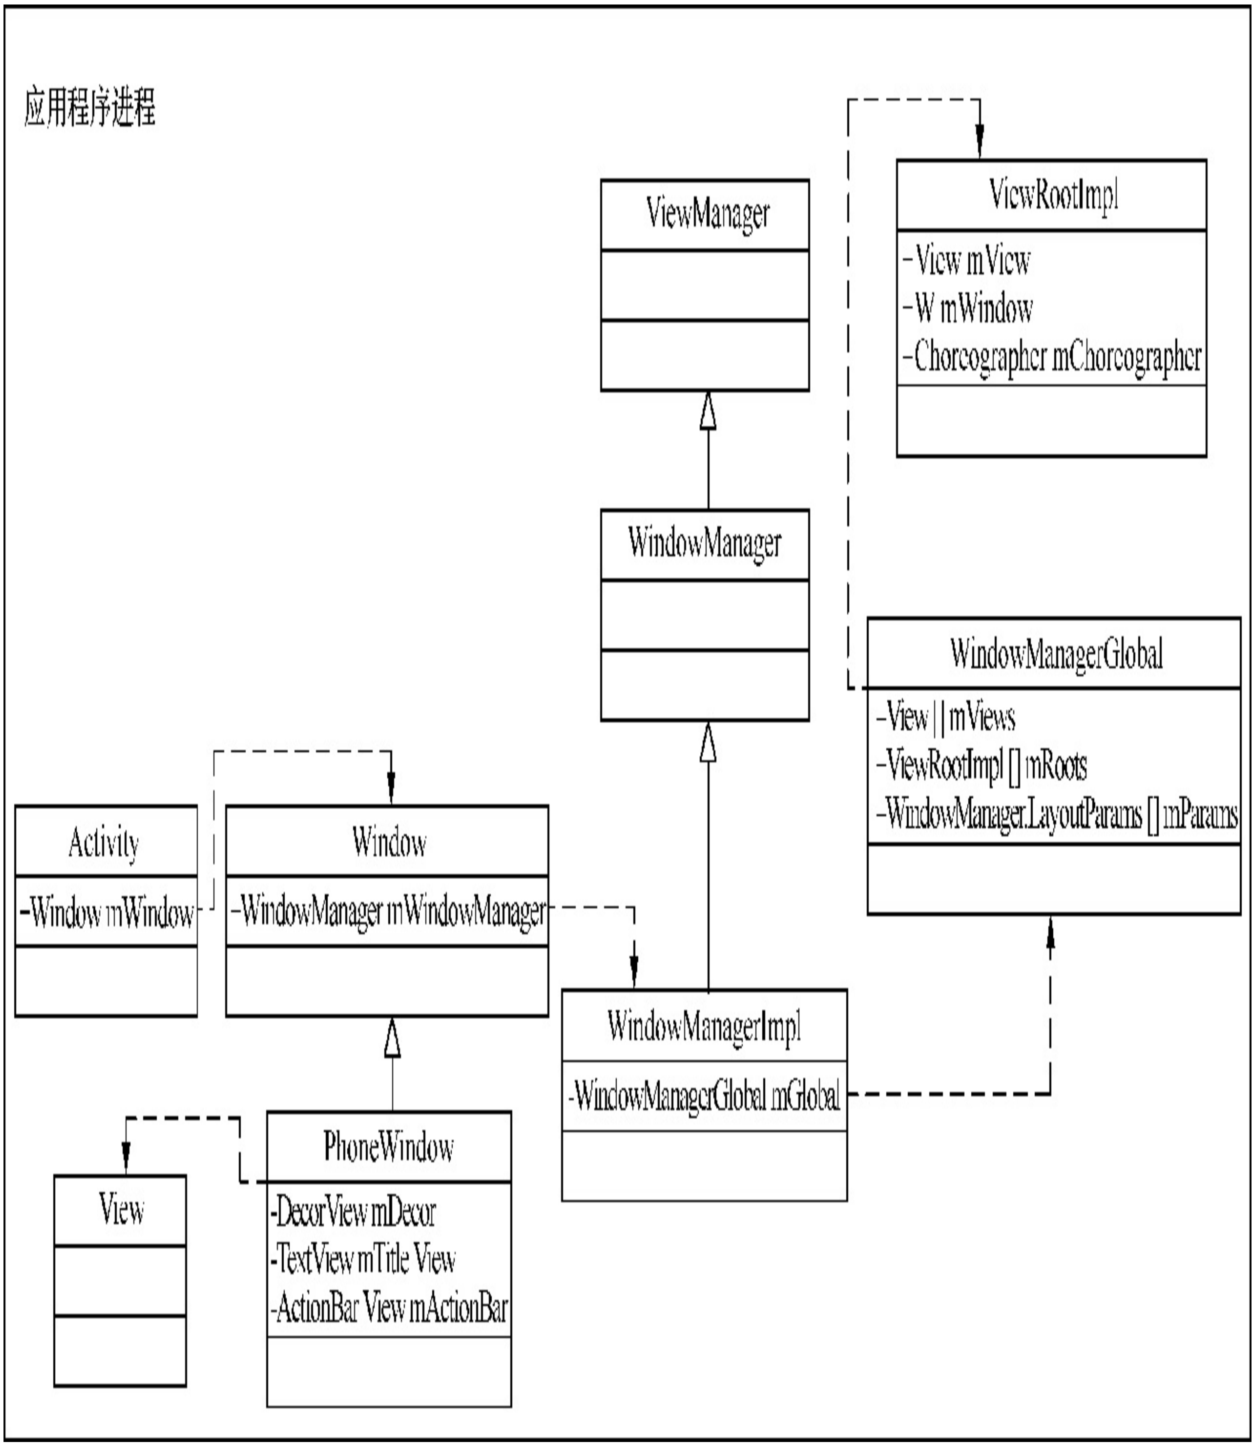

▲图11-1　应用程序中的View框架

Activity是应用程序各组件中使用率最高的，专门设计用于UI界面的显示和处理（当然，这并不意味着在其他组件中就一定无法显示UI，只不过需要做很多额外的工作）。对于应用开发人员来说，他们可以利用SDK向导来生成一个带Activity的应用程序模板，再根据具体需求“加工”Android提供的“半成品”—— setContentView、onCreate、onStart等方法，从而快速定制出应用程序；而从系统实现的角度来分析，Android为了提供尽可能便捷的“半成品”而做了很多努力。

在对这部分源码进行讲解前，我们发现以下几个问题是很多开发者共同的困惑。

- View和ViewRoot

如果以xml文件来描述UI界面的layout，可以发现里面的所有元素实际上都形成了树状结构的关系，比如：

```
<LinearLayout xmlns:android="http://schemas.android.com/apk/res/a
    android:id="@+id/top"...>
 <LinearLayout android:id="@+id/digits_container"...>
  <com.android.contacts.dialpad.DigitsEditText android:id="@+id/d
  <ImageButton  android:id="@+id/deleteButton".../>
 </LinearLayout>
 <View android:id="@+id/viewEle".../>
</LinearLayout>
```

这个xml文件中各元素的关系如图11-2所示。

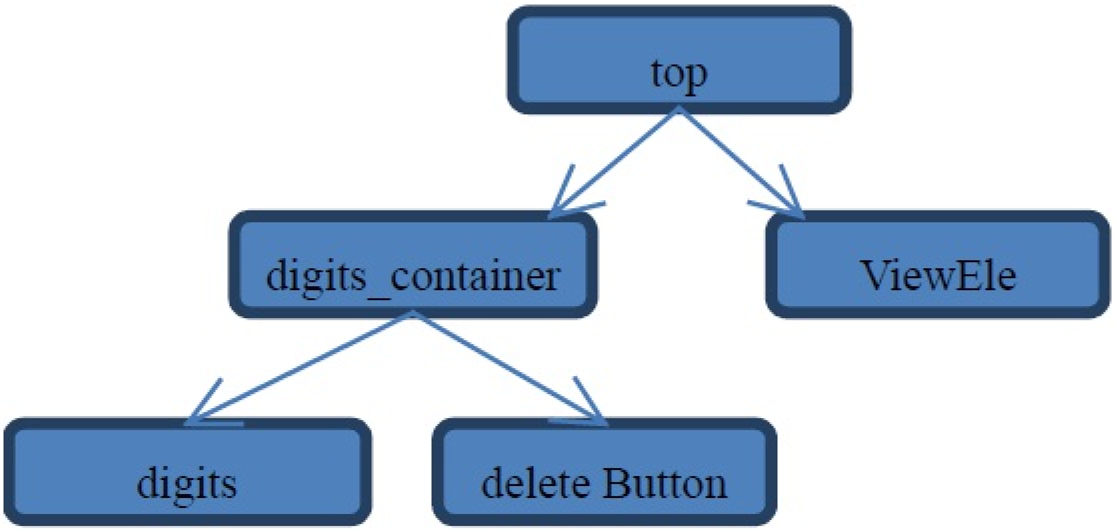

▲图11-2 xml文件中各元素的关系图

从名称来理解，“ViewRoot”似乎是“View树的根”。这很容易让人产生误解，因为ViewRoot并不属于View树的一分子。从源码实现上来看，ViewRoot和View对象并没有任何“血缘”关系，它既非View的子类，也非View的父类。更确切地说，ViewRoot可以被理解为“View树的管理者”——它有一个mView成员变量，指向的是它所管理的View树的根，即图中id为“top”的元素。

ViewRoot的核心任务就是与WindowManagerService进行通信，我们在后面小节会详细介绍。

- Activity和Window的关系

我们知道，Activity是支持UI显示的，那么它是否直接管理View树或者ViewRoot呢？答案是否定的。Activity并没有与这两者产生直接的联系，这中间还有一个被称为“Window”的对象。

具体而言，Activity内部有一个mWindow成员变量。如下所示：

```
private Window mWindow;
```

Window的字面意思是“窗口”，这很好地解释了它存在的意义。Window是基类，根据不同的产品可以衍生出不同的子类——具体则是由

系统在Activity.attach中调用PolicyManager.make NewWindow决定的，目前版本的Android系统默认生成的都是PhoneWindow。

- Window与WindowManagerImpl的关系

以“Window”开头的类有不少，如Window、WindowManager、WindowManagerImpl等，为什么需要这么多的相似类呢？

先来看Window，它是面向Activity的，表示“UI界面的外框”；而“框里面”具体的东西包括布局和内容等，是由具体的Window子类，如PhoneWindow来规划的。但无论最终生成的窗口怎样，Activity都是不需要修改的。

Window的另一层含义是要与WindowManagerService进行通信，但它并没有直接在自身实现这一功能。原因就是：一个应用程序中很可能存在多个Window。如果它们都单独与WMS通信，那么既浪费资源，又会造成管理的混乱。换句话说，它们需要统一的管理。于是就有了WindowManager，它作为Window的成员变量mWindowManager存在。这个WindowManager是一个接口类，其真正的实现是WindowManagerImpl，后者同时也是整个应用程序中所有Window的管理者。因而WindowManager与WindowManagerImpl的关系有点类似于“地方与中央”：地方为实施中央的“政策”提供了一个“接口”，然后汇总到中央进行管理。

- ViewRoot和WindowManagerImpl的关系

在早期的系统版本中，WindowManagerImpl在每个进程中只有一个实例。调用它必须使用如下语句：

```
WindowManagerImpl.getDefault();
```

在WindowManagerImpl内部，存在3个全局变量：

```
private View[] mViews;
private ViewRootImpl[] mRoots;
private WindowManager.LayoutParams[] mParams;
```

它们分别用于表示View树的根节点、ViewRoot以及Window的属性。由此也可以看出，一个进程中不仅有一个ViewRoot；而Activity与ViewRoot则是一对一的关系。

Android 4.3对此做了修改，WindowManagerImpl不再直接存储上述3个数组变量，而是由一个称为“WindowManagerGlobal”的类统一管理。另外，新版本还对各个类的关系进行了梳理，剔除了一些历史遗留下来的无关类。当然，其统一管理ViewRoot与View树的本质是没有变的，正所谓“换汤不换药”。

- ViewRoot与WindowManagerService的关系

每一个ViewRootImpl内部，都有一个全局变量：

```
static IWindowSession sWindowSession;
```

这个变量用于ViewRoot到WMS的连接，它是ViewRoot利用WMS的opneSession()接口来创建得到的。在此基础上，ViewRoot也会通过IWindowSession.add()方法提供一个IWindow对象——从而让WMS也可以通过这个Binder对象来与ViewRoot进行双向通信。

我们可以用图11-3来描述这些类之间的关系。

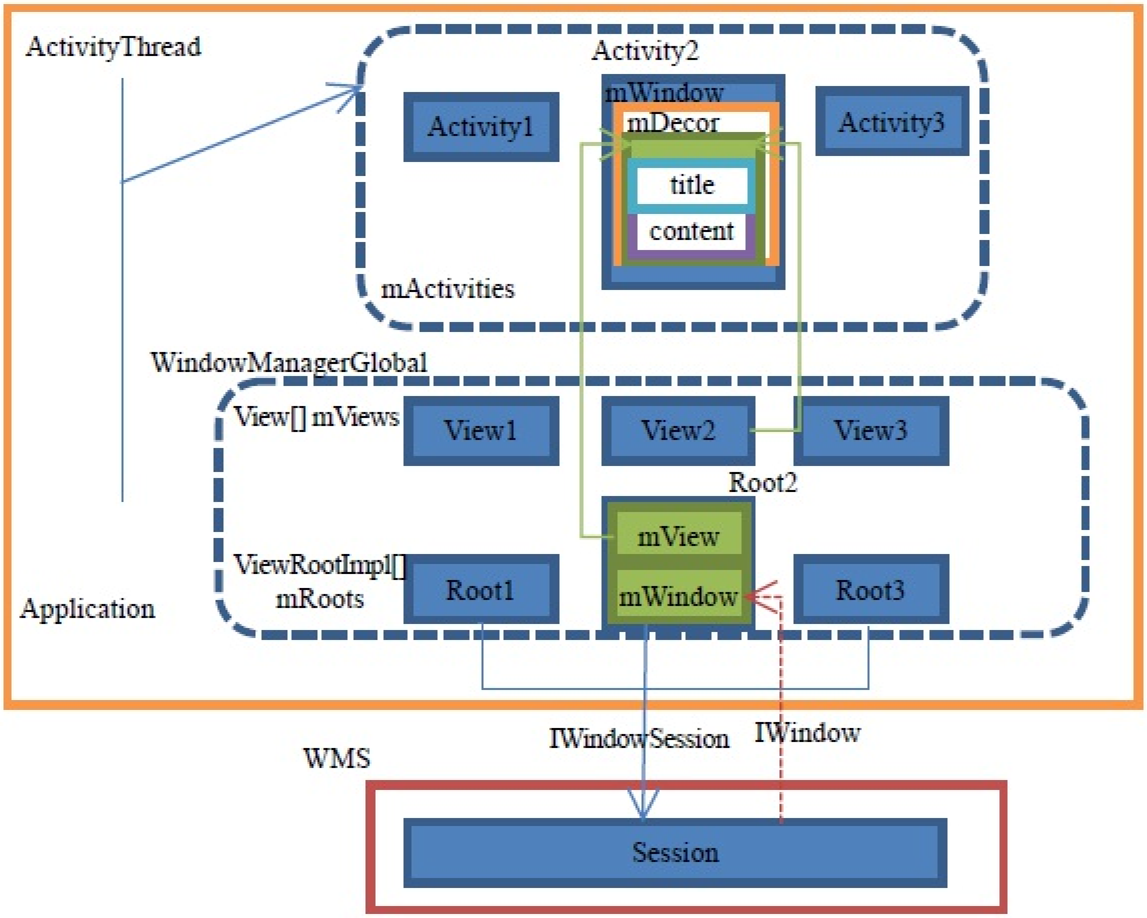

▲图11-3　Activity、WindowManagerGlobal和WMS等的关系图

如图11-3所示，每个Application都有一个ActivityThread主线程以及mActivities全局变量，后者记录了运行在应用程序中的所有Activity对象。一个Activity对应唯一的WindowManager以及ViewRootImpl。WindowManagerGlobal作为全局管理者，其内部的mRoots和mViews记录了各Activity的ViewRootImpl和View树的顶层元素。ViewRootImpl的另一个重要角色就是负责与WMS进行通信。从ViewRootImpl到WMS间的通信利用的是IWindowSession，而反方向则是由IWindow来完成的。

11.2 Activity中View Tree的创建过程

Activity与其他组件最大的不同，就是其内部拥有完整的界面显示机制，这涉及了ViewRootImpl，Window以及由它们管理的View Tree等。前几个章节讨论应用程序窗口的启动流程时，我们曾大致讲解了View Tree的建立要点——现在是时候把其中的细节逐一剖析清楚了，如图11-4所示。

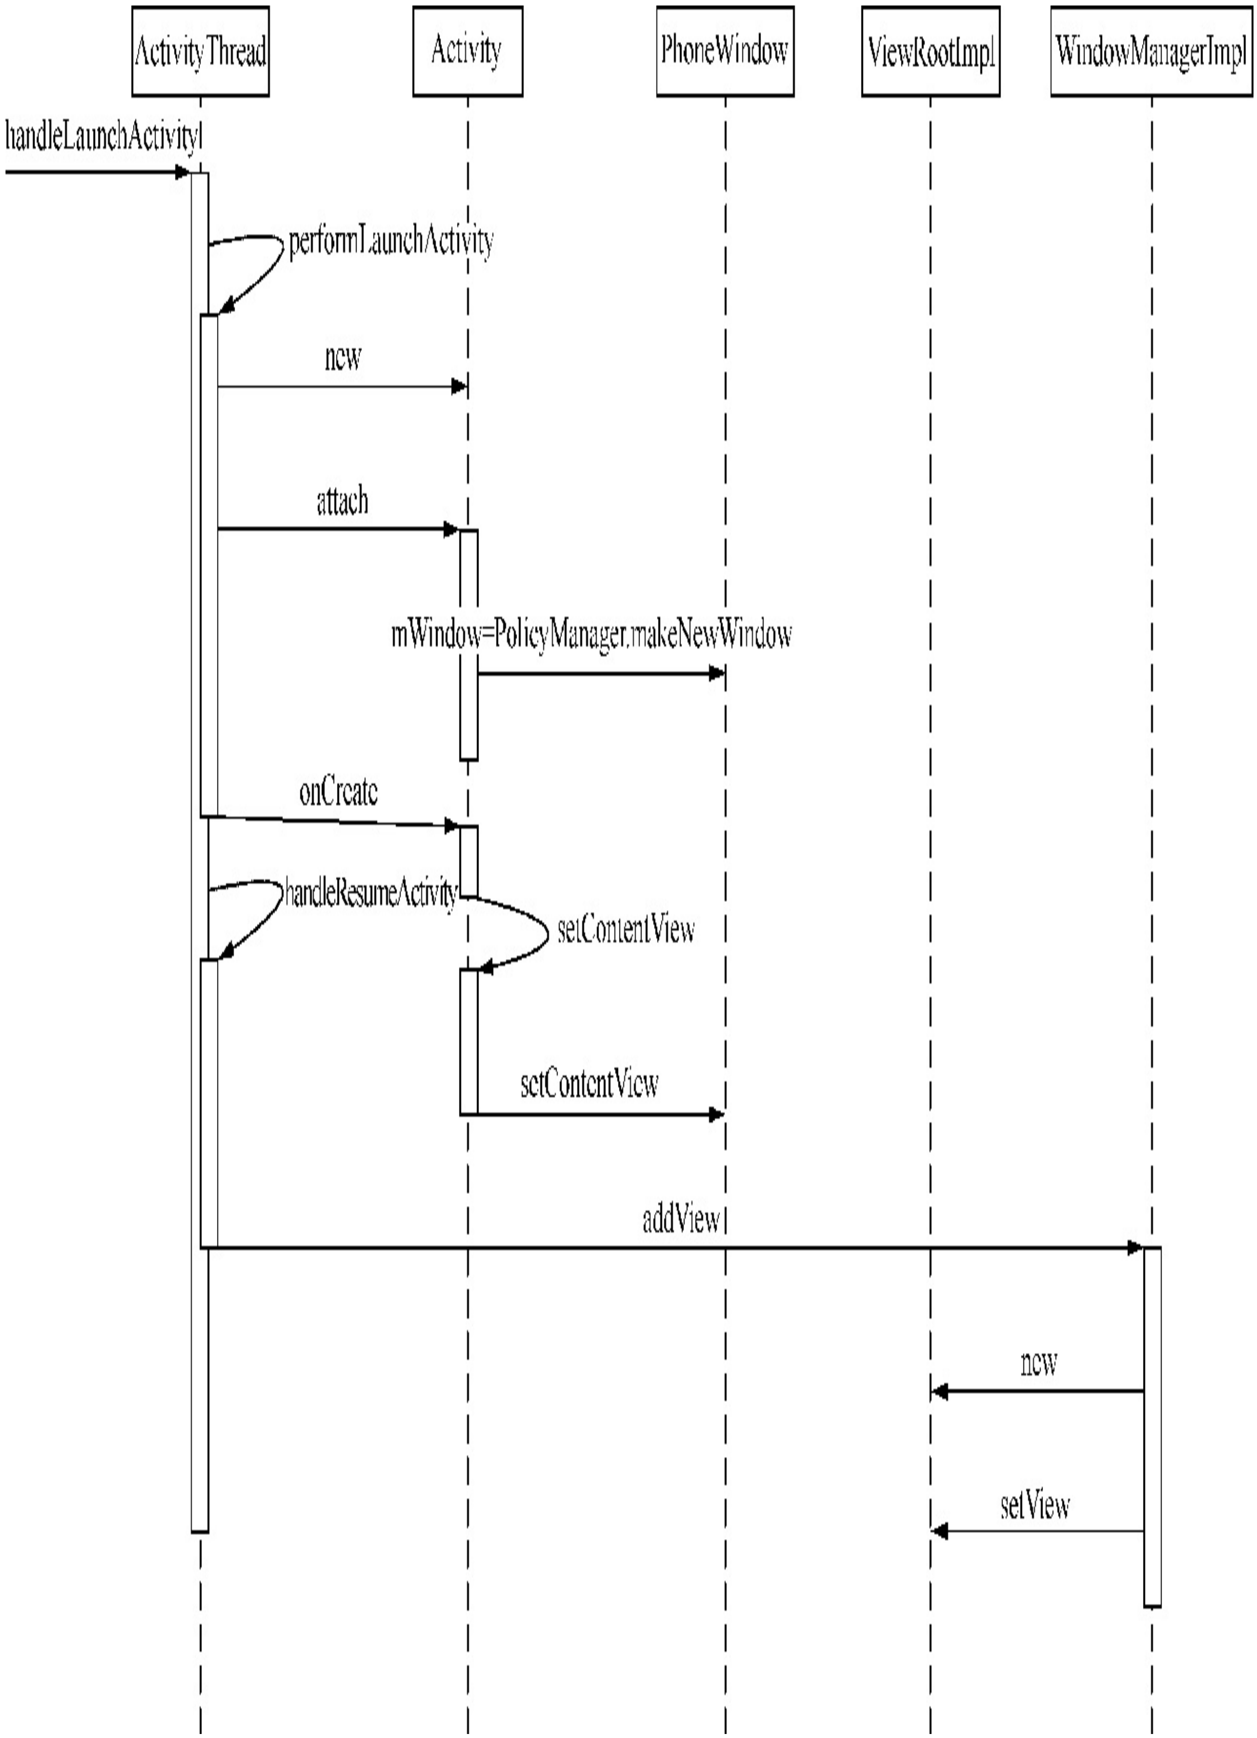
ActivityThread
Activity
PhoneWindow
ViewRootImpl
WindowManagerImpl
handleLaunchActivity
performLaunchActivity
new
attach
mWindow=PolicyManager.makeNewWindow
onCreate
handleResumeActivity
setContentView
setContentView
addView
new
setView

▲图11-4　View Tree的建立流程图

参与View Tree创建的有几个主体，即ActivityThread、Activity、PhoneWindow、ViewRootImpl和WM（这里先不严格区分是本地的WindowManager还是服务端的WindowManagerService）。

主要流程如下：

Step1. 作为应用程序的主线程，ActivityThread负责处理各种核心事件。比如“AMS通知应用进程去启动一个Activity”这个任务，最终将转化为ActivityThread所管理的LAUNCH_ ACTIVITY消息，然后调用handleLaunchActivity，这是整个ViewTree建立流程的起点。

Step2. 在handleLaunchActivity内部，又可以细分为两个子过程：

- performLaunchActivity；
- handleResumeActivity（注意，Resume的处理时机有多种情况，我们以此为例）。

具体源代码如下：

```
/*frameworks/base/core/java/android/app/ActivityThread.java*/
private void handleLaunchActivity(ActivityClientRecord r, Intent
    …
    Activity a = performLaunchActivity(r, customIntent);//启动(加载
    if (a != null) {
        handleResumeActivity(r.token, false, r.isForward);//Resum
        …
    }…
```

下面结合本小节开头的序列图，分别对这两个函数进行解析。

1．performLaunchActivity

```
private Activity performLaunchActivity(ActivityClientRecord r, In
        …
        Activity activity = null;
        try {
            java.lang.ClassLoader cl = r.packageInfo.getClassLoad
```

```
        activity = mInstrumentation.newActivity(cl, component
        /*加载这个Activity对象*/
        …
    } catch (Exception e) {
       …
    }

    try {
        Application app = r.packageInfo.makeApplication(false
        …
        if (activity != null) {
            …
            activity.attach(appContext, this, getInstrumentat
                    r.ident, app, r.intent, r.activityInfo, t
                    r.embeddedID, r.lastNonConfigurationInsta
            …
            mInstrumentation.callActivityOnCreate(activity, r

            …
    } catch (SuperNotCalledException e) {
        …
        return activity;
    }
```

这个函数的主要任务是生成一个Activity对象，并调用它的attach方法，然后通过Instrumentation.callActivityOnCreate间接调用Activity.onCreate。其中attach将为Activity内部众多全局变量赋值——最重要的就是mWindow。源代码如下：

```
mWindow = PolicyManager.makeNewWindow(this);
```

这里得到的就是一个PhoneWindow对象，它在每个Activity中有且仅有一个实例。我们知道，“Window”在Activity中可以被看成“界面的框架抽象”，所以有了Window后，下一步肯定还要生成具体的View内容，即Activity中的mDecor。Decor的原义是“装饰”。换句话说，它除了包含Activity中实际想要显示的内容外，还必须具备所有应用程序共同的“装饰”部分，如Title，ActionBar等（最终是否要显示这些“装饰”，则取决于应用程序自身的需求）。

产生DecorView的过程是由setContentView发起的，这也就是开发者需要在onCreate时调用这个函数的原因。而onCreate本身则是由mInstrumentation.callActivityOnCreate(activity, r.state)间接调用的，有兴趣的读者可以自行分析。

Activity中的setContentView只是一个中介，它将通过对应的Window对象来完成DecorView的构造：

```
/*frameworks/base/policy/src/com/android/internal/policy/impl/Pho
      public void setContentView(int layoutResID) {
        if (mContentParent == null) {//如果是第一次调用这个函数的情况下
            installDecor();//需要首先生成mDecor对象
        } else {
            mContentParent.removeAllViews();//不是第一次调用此函数，先
        }
        mLayoutInflater.inflate(layoutResID, mContentParent);//根
      …
    }
```

变量mContentParent是一个ViewGroup对象，它用于容纳“ContentView”。当mContentParent为空时，说明是第一次调用setContentView。此时mDecor也必定为空，因而调用installDecor创建一个DecorView；否则先清理mContentParent中已有的所有View对象。最后通过layoutResID来inflate新的内容（mContentParent就是这个由layoutResID生成的View树的根）。从中我们也可以看出，setContentView在应用进程中是允许多次调用的，只是一般不这么做。

函数installDecor有两个任务，即生成mDecor和mContentParent。我们先来看看mDecor的生成过程：

```
    private void installDecor() {
        if (mDecor == null) {
            mDecor = generateDecor();
            …
        }
```

函数generateDecor实际上只是new一个DecorView对象，而返回值则赋予mDecor。DecorView继承自FrameLayout，后面就能看到这样做的原因。

变量mContentParent的创建过程与mDecor有关联，代码如下：

```
        if (mContentParent == null) {
            mContentParent = generateLayout(mDecor);
            …
        }
    }//installDecor结束
```

可以看到，mContentParent是通过generateLayout函数生成的：

```
protected ViewGroup generateLayout(DecorView decor) {
   TypedArray a = getWindowStyle();//获取窗口样式
   mIsFloating =a.getBoolean(com.android.internal.R.styleable
   ting, false);
   …
   int layoutResource;
   int features = getLocalFeatures();
   if ((features & ((1 << FEATURE_LEFT_ICON) | (1 << FEATURE_
       …//根据具体的样式为layoutResource挑选匹配的资源
   } else if ((features & ((1 << FEATURE_PROGRESS) | (1 <<
               FEATURE_INDETERMINATE_PROGRESS))) != 0
               && (features & (1 << FEATURE_ACTION_BAR)) == 0
       …
   } else if ((features & (1 << FEATURE_CUSTOM_TITLE)) != 0)
      …
   } else if ((features & (1 << FEATURE_NO_TITLE)) == 0) {
      …
   } else if ((features & (1 << FEATURE_ACTION_MODE_OVERLAY))
       …
   } else {
      …
   }
   …
   View in = mLayoutInflater.inflate(layoutResource, null);//
   decor.addView(in, new ViewGroup.LayoutParams(MATCH_PARENT,
   ViewGroup contentParent = (ViewGroup)findViewById(ID_ANDRO
   …
   return contentParent;
}
```

上面的代码段分为3个步骤。

- 取出Window样式，如windowIsFloating、windowNoTitle，windowFullscreen等。这是通过分析styleable.Window获得的，如下：

```
mWindowStyle = mContext.obtainStyledAttributes(com.android.intern
```

- 根据上一步得出的样式来挑选符合要求的layout资源，并由layoutResource来表示。

比如通过以下语句：

```
(features & ((1 << FEATURE_LEFT_ICON) | (1 << FEATURE_RIGHT_ICON)
```

可以得知应用程序的UI界面是否需要左、右两个icon——满足这一要求的layout也有两种，我们还需要根据mIsFloating进一步决定是com.android.internal.R.attr.dialogTitleIconsDecorLayout或者com.android.internal.R.layout.screen_title_icons。顺便提一下，系统framework提供的这些默认layout文件统一存放在frameworks/base/core/res/res/layout中。

其他几个else分支的处理过程都类似，读者可以自行阅读。要特别注意的是，不论哪种layout都必须包含id值为“content”的View对象，否则将发生异常。

- 根据layoutResource指定的layout(xml)文件，来inflate出相应的View对象。然后把这一新对象addView到mDecor（DecorView是一个FrameLayout）中；最后，整个generateLayout函数的返回值是一个id为ID_ANDROID_CONTENT= com.android.internal.R.id.content的对象，即mContentParent。

DecorView的布局之一如图11-5所示。

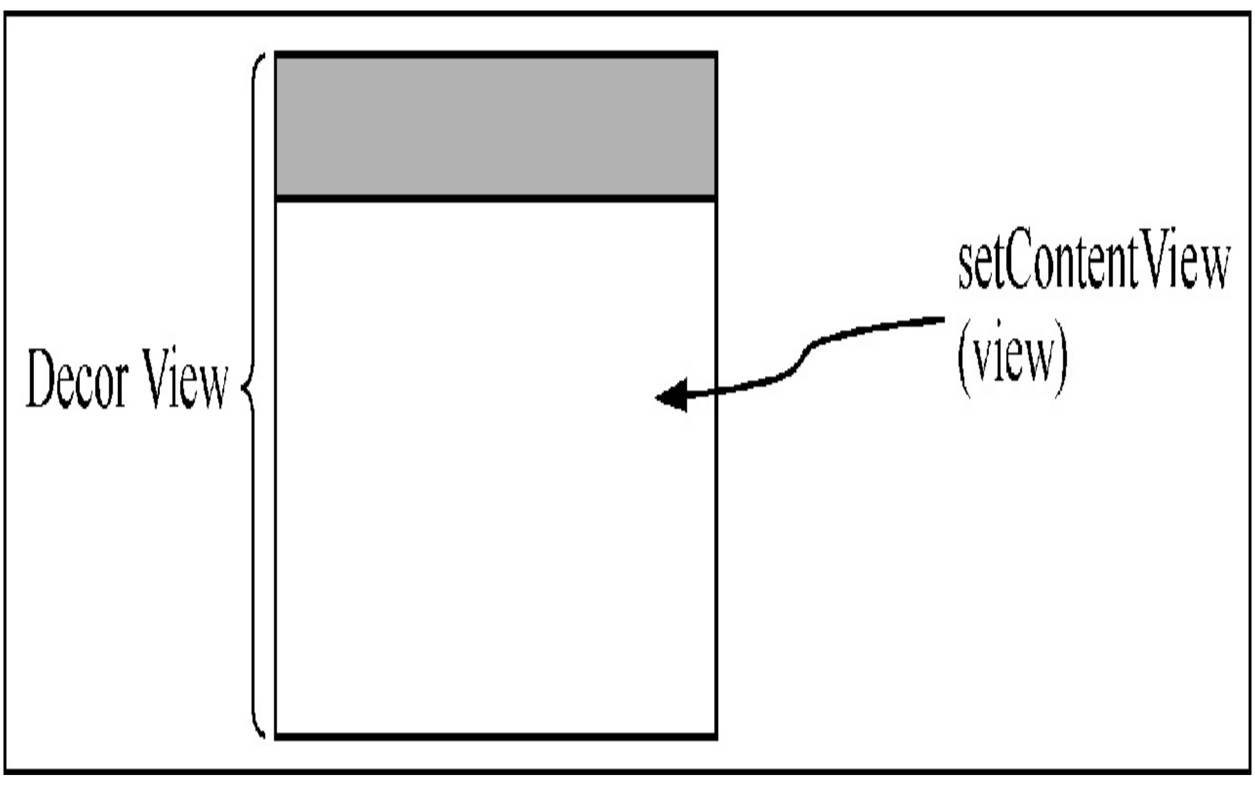

▲图11-5　DecorView的布局之一

由此可知，setContentView实际上做的工作就是把应用程序想要显示的视图（ContentView）加上系统策略中的其他元素（比如Title，Action），合成出用户所看到的最终应用程序的界面（如图11-5所示）。需要注意的是，setContentView并不负责将这一视图真正地显示出来。有一个实验也可以证明一点，读者可以尝试在Activity中不调用setContentView，看下最终应用程序的界面是否还能照常显示出来——只是中间的“content”部分为空而已。

顺便说一下，Android系统不同版本间的UI界面样式差异不小。因而如果是需要兼容多个版本的应用程序，在Release之前最好挑选几个有代表性的版本进行测试——特别是需要针对Android 2.3、2.2和3.0以上的3种版本进行验证，因为它们之间的变更最大。

比如应用程序中很常用的Menu（总共有3类），在不同版本间的样式区别如下。

- Options Menu/Action Bar

这是最常用的一类菜单。在Android 2.3版本以下，通过按Menu键就可以调出来（显示在底部）；而且如果菜单选项超过6个，还会出现“More”的字样。而3.0以后的版本，则被Action Bar所取代。两者的区别如图11-6所示。

- Context Menu/Contextual Action Mode

从名称可以推断出，它是和“上下文环境”有关联的一类菜单。比如我们可以通过长按ListView的某个Item来调出它的Context Menu。这类菜单在3.0以上版本系统中有两种可选的样式，即Context Menu和Contextual Action Mode。前者是Floating Menu，即悬浮于当前界面之上，而后者则是通过在屏幕上方显示一条操作栏来提供操作界面（这种设计的特点是“内容”不会被挡住，因而可以方便用户选择多个元素，如文件管理器中的批量删除）。它们的区别如图11-7所示。

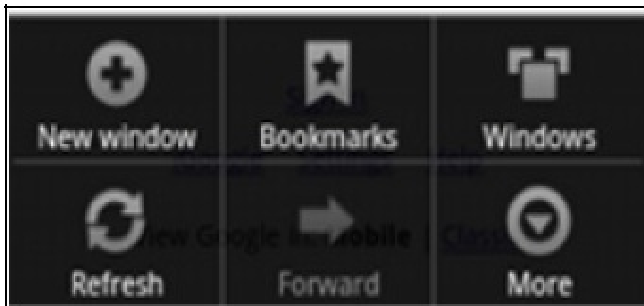

2.3 以下版本的 Options Menu

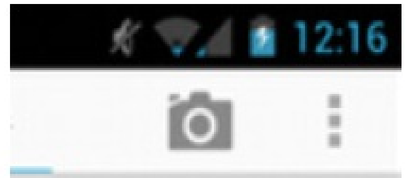

3.0 以上版本的 Action Bar，除了最右边的默认按钮外，用户还可以自定义需要显示的 Action。比如图中的 Camera 图标就是自定义的

▲图11-6　Options Menu和Action Bar的区别

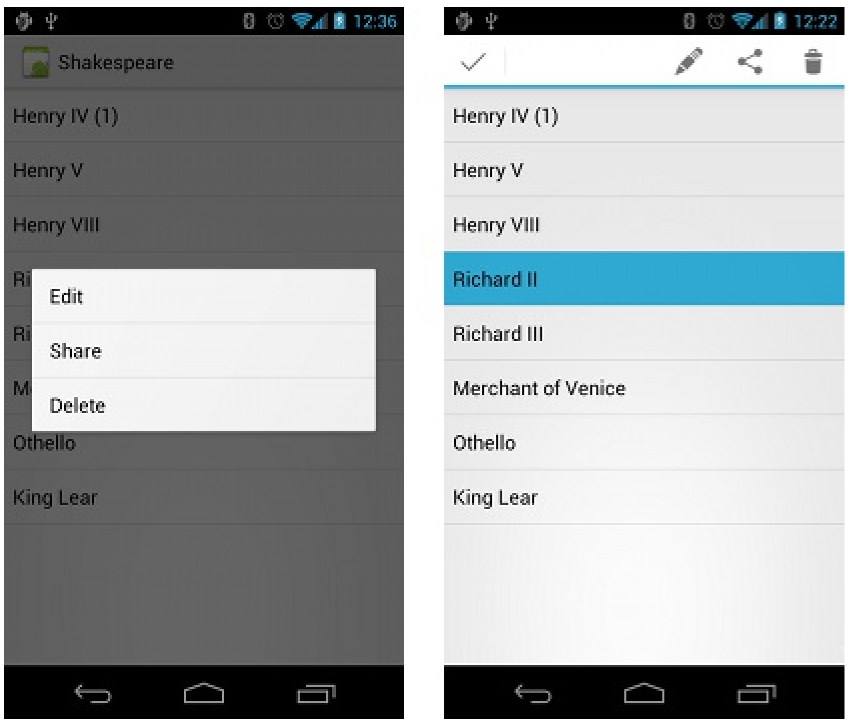

Context Menu　　　　Contextual Action Mode

▲图11-7　Context Menu和Contextual Action Mode的区别

- Popup Menu

弹出式菜单和其他样式最大的区别在于其出现位置是基于激活它的View而定的，这样用户就很清楚这一菜单是针对界面中的哪个View而设置的了。

2．handleResumeActivity

通过performLaunchActivity，Activity内部已经完成了Window和DecorView的创建过程。可以说整棵View Tree实际上已经生成了，只不过还不为外界所知。换句话说，无论是WMS还是SurfaceFlinger，都还不知道它的存在。所以接下来还需要把它添加到本地的WindowManagerGlobal中（还记得吗？WindowManagerGlobal中有3个数组mViews，mRoots和mParams），继而注册到WMS里。

这其中就涉及ViewRootImpl的相关操作：

```
    final void handleResumeActivity(…) {…
        ActivityClientRecord r = performResumeActivity(token, cle
        Activity. onResume最终被调用*/
        if (r != null) {
            final Activity a = r.activity;
            …
            if (r.window == null && !a.mFinished && willBeVisible
                r.window = r.activity.getWindow();//Activity对应的
                View decor = r.window.getDecorView();//最外围的mDe
                decor.setVisibility(View.INVISIBLE);//先设置为不可
                ViewManager wm = a.getWindowManager();//即WindowMa
                WindowManager.LayoutParams l = r.window.getAttrib
                a.mDecor = decor;
                l.type = WindowManager.LayoutParams.TYPE_BASE_APP
                l.softInputMode |= forwardBit;
                if (a.mVisibleFromClient) {
                    a.mWindowAdded = true;
                    wm.addView(decor, l);//首先添加decor到本地的全局
                }
            } else if (!willBeVisible) {
                …
            }
…
```

我们将上述函数中涉及的相关重点部分高亮显示，以方便大家阅读。可以看到，变量wm声明的类型是ViewManager。这是因为WindowManager继承自ViewManager，而getWindowManager真正返回的是一个WindowManagerImpl对象。后者的addView又间接调用了WindowManager Global中的实现：

```
/*frameworks/base/core/java/android/view/WindowManagerGlobal.java
    public void addView(View view, ViewGroup.LayoutParams params,
```

```
        Display display, Window parentWindow) {…
    ViewRootImpl root;
    View panelParentView = null;
    synchronized (mLock) {…
        int index = findViewLocked(view, false);//是不是添加过此
        …
        root = new ViewRootImpl(view.getContext(), display);/
                                                     ViewRoo
        view.setLayoutParams(wparams);
        if (mViews == null) {//第一次添加元素到mViews中
            index = 1;
            mViews = new View[1];
            mRoots = new ViewRootImpl[1];
            mParams = new WindowManager.LayoutParams[1];
        } else {//不是第一次操作
            …//动态分配数组容量，代码省略
        }
        index--;
        mViews[index] = view;
        mRoots[index] = root;
        mParams[index] = wparams;
    }
    try {
        root.setView(view, wparams, panelParentView);//将View
    } catch (RuntimeException e) {…
    }
}
```

如果上面代码段中的index小于0，表示之前未添加过此View对象，因而程序可以继续执行；否则说明调用者多次添加了同一个View对象，因而函数直接返回。

接下来addView需要添加一个新的ViewRootImpl到WindowManagerGlobal的mRoots数组中。由于事先并不知道一个应用程序中会有多少ViewRoot存在，WindowManagerGlobal采用的是动态存储方法。具体细节在前面章节已经做过分析，这里不再赘述。

除了mRoots，WindowManagerGlobal中还有另外两个重要数组。其中mViews记录的是DecorView，mParams记录的是布局属性。这3个数组中的元素是一一对应的，即同一个index在3个数组中得到的元素描述的是同一个Activity中的View树、ViewRoot和布局属性。

最后，函数通过root.setView把DecorView同步记录到

ViewRootImpl内部的mView变量中。因为后面ViewRootImpl将会频繁访问到这棵View Tree——比如当收到某个按键事件或者触摸事件时，需要把它传递给后者进行处理。

由此一个Activity中的一棵View Tree就完整地建立起来，并纳入本地的全局管理中。不过需要指出的是，到目前为止我们的分析仍然停留在本地应用进程中。或者说我们还没看到与WMS及SurfaceFlinger发生实质性交互的地方，如向WMS申请一个用于显示的窗口（注意和PhoneWindow的概念区别开来）；也还没有分析View Tree中的各个对象是如何借用这个Window来绘制最终的UI内容的。

接下来将为读者一一揭开这些问题的答案。

11.3　在WMS中注册窗口

上一节我们虽然看到了整棵View Tree的建立过程，但整个分析还没有跳出应用程序进程的范畴。

首先还要再次强调一下“窗口”的概念，以免引起混淆。本章前几个小节提到的PhoneWindow继承自Window类，它表达了窗口的一种约束机制；而WMS中的Window则是一个抽象的概念，其有一个WindowState用于描述状态。如果读者还是觉得比较困惑的话，也可以简单地理解：PhoneWindow是应用进程端对于“窗口”的描述，WindowState则是WMS中对“窗口”的描述。

当ViewRootImpl构造的时候，它需要建立与WMS通信的双向通道。前面已经讨论过了，分别是：

- ViewRootImplWMS: IwindowSession；
- WMSViewRootImpl: Iwindow。

因为WMS是在ServiceManager中注册的实名Binder Server（详见Binder章节的描述），因而任何程序都能在任何时候通过向Service Manager发起查询来获取WMS的服务。而IWindowSession和IWindow则是两个匿名的Binder Server，它们需要借助一定的方式才能提供服务。

其流程如图11-8所示。

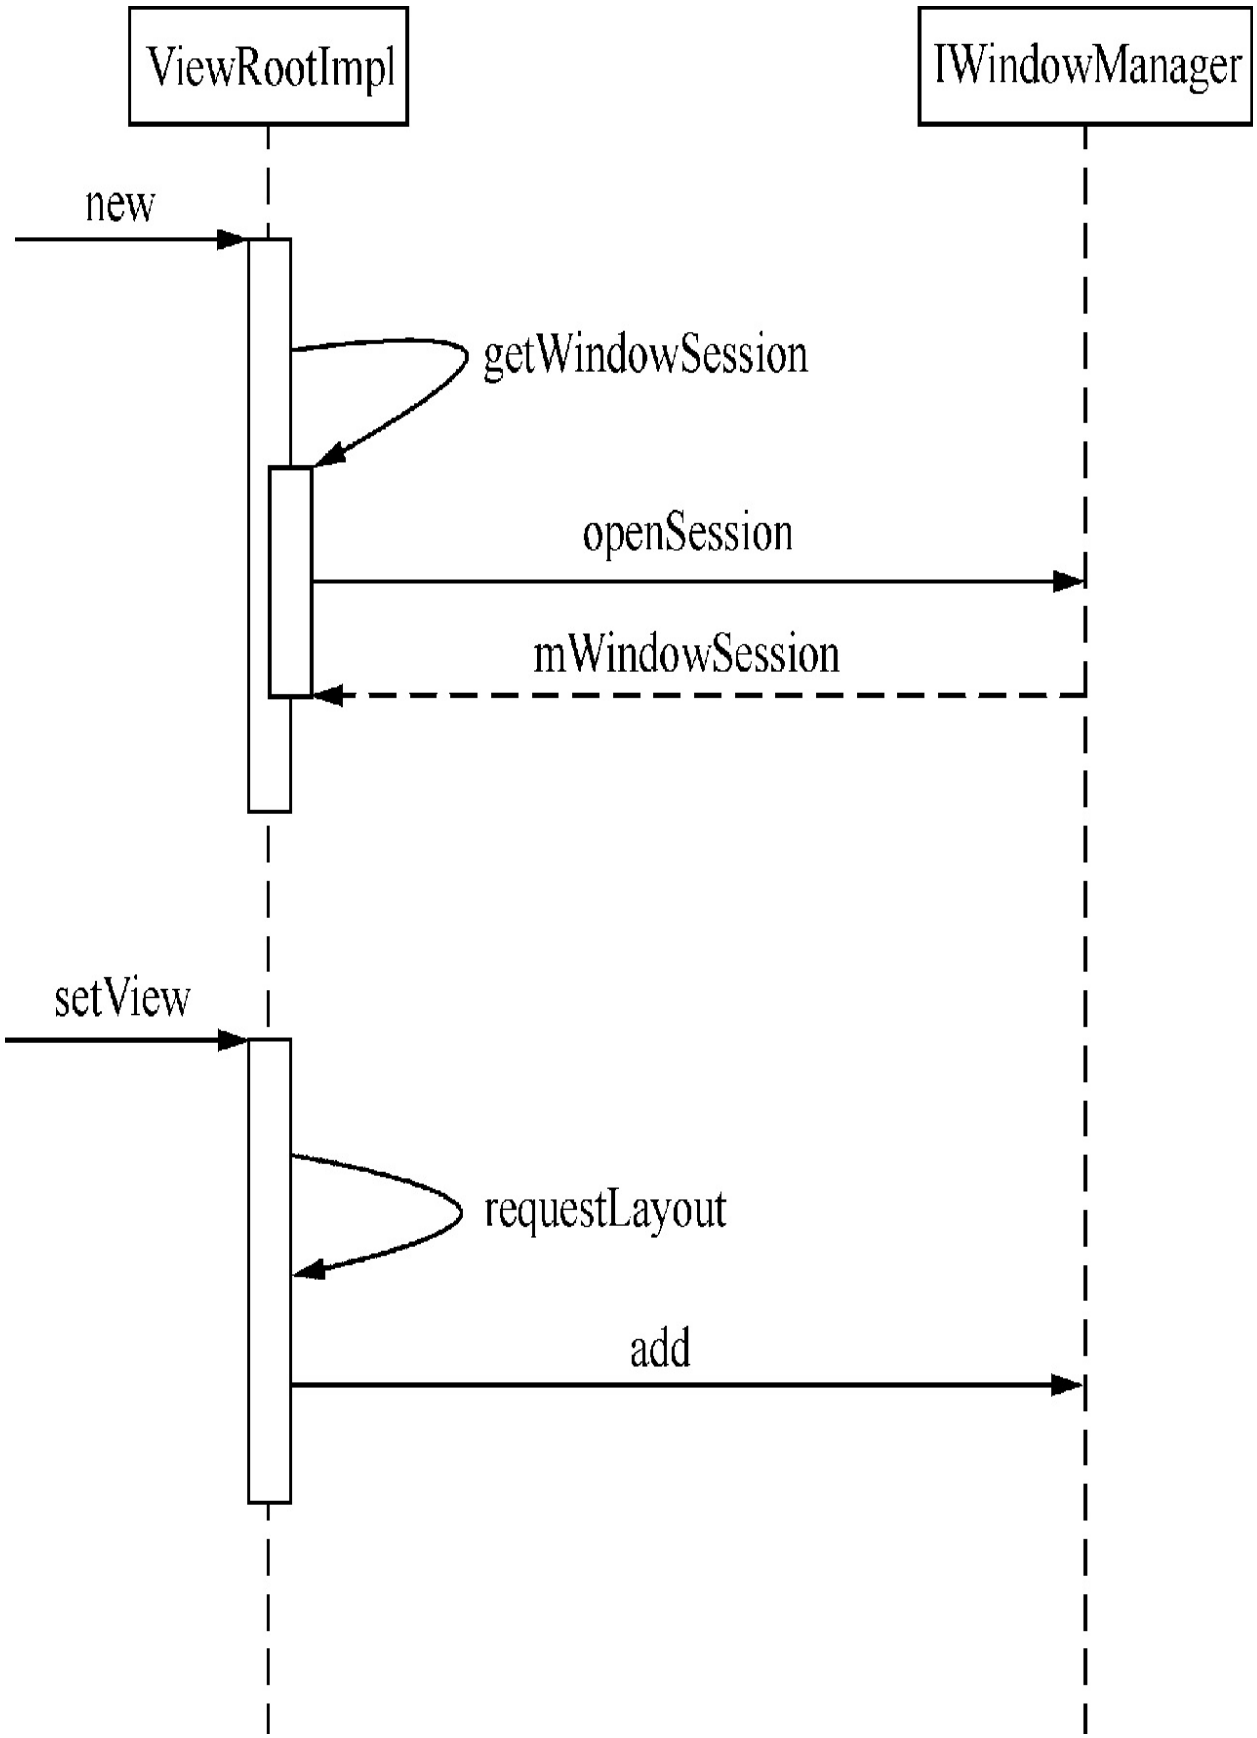
ViewRootImpl
IWindowManager
new
getWindowSession
openSession
mWindowSession
setView
requestLayout
add

▲图11－8 如何在WMS中注册窗口

Step1. ViewRootImpl在构造函数中，首先会利用WMS提供的openSession接口打开一条Session通道，并存储到内部的mWindowSession变量中：

```
public ViewRootImpl(Context context, Display display) {…
        mWindowSession = WindowManagerGlobal.getWindowSession();//
        …
        mWindow = new W(this);//IWindow
        …
    }
```

函数getWindowSession负责建立应用程序与WMS间的Session连接：

```
public static IWindowSession getWindowSession() {
        synchronized (WindowManagerGlobal.class) {
            if (sWindowSession == null) {
                try {
                    InputMethodManager imm = InputMethodManager.ge
                    IWindowManager windowManager = getWindowManage
                    sWindowSession = windowManager.openSession(imm
                                                                imm.
                    …
                } catch (RemoteException e) {
                    Log.e(TAG, "Failed to open window session", e)
                }
            }
            return sWindowSession;
        }
}
```

如果sWindowSession不为空，那么就没必要再重复打开Session连接了；否则需要先通过ServiceManager来获取WMS服务，再利用它提供的openSession接口来建立与WMS的“通道”。

有必要说明的是，上述代码段中的windowManager变量和前一小节handleResumeActivity中见到的WindowManager对象是不一样的，我们特别把它们列出来进行比较。

在handleResumeActivity中：

```
ViewManager wm = a.getWindowManager();
```

这句代码中的wm是ViewManager，即WindowManager类的基类，最终则由WindowManagerImpl来实现。

而上面的windowManager变量则是：

```
    public static IWindowManager getWindowManagerService() {
        synchronized (WindowManagerGlobal.class) {
            if (sWindowManagerService == null) {
                sWindowManagerService = IWindowManager.Stub.asInt
                       ServiceManager.getService("window"));
            }
            return sWindowManagerService;
        }
    }
```

我们可以这么理解这两种WindowManager：其中一种完全是属于本地端的，存储于应用进程内部用于窗口管理的相关事务；另一种则是WindowManagerService在本地进程中的代理。前者最终由WindowManagerImpl来实现，而后者则是由WindowManagerService在远程端实现。

Step2. 在前一小节我们看到，函数addView在最后会调用ViewRootImpl.setView——这个函数一方面会把DecorView，也就是View树的根设置到VierRootImpl中；另一方面会向WMS申请注册一个窗口，同时将ViewRootImpl中的W（IWindow的子类）对象作为参数传递给WMS。

```
/*frameworks/base/core/java/android/view/ViewRootImpl.java*/
    public void setView(View view, WindowManager.LayoutParams att
                            View panelParent View) {
        synchronized (this) {
            if (mView == null) {
                mView = view;//ViewRoot内部记录了它所管理的View树的根
                …
                requestLayout();//执行Layout
                …
                try {…
                    res = mWindowSession.addToDisplay(mWindow, mS
                            getHostVisibility(), mDisplay.getDisp
                            mAttachInfo.mContentInsets, mInputCha
                } catch (RemoteException e) {…
```

```
                } finally {…
                }…
            }…
    }
```

关于requestLayout所引发的遍历过程，可以参见后面小节的介绍，这里先不做详细分析。上述代码段中最关键的一步，就是通过IWindowSession提供的addToDisplay（这个函数将调用WMS的addWindow），向WMS申请注册一个窗口。这些内容在前一章节讲解WMS时已经系统讨论过，不清楚的读者可以返回复习下。

11.4 ViewRoot的基本工作方式

在讲解View树中具体的事务处理前，有必要先给大家分析下ViewRoot的基本工作方式，这有助于大家在接下来众多烦琐问题的剖析中把握事件的核心。

我们知道，每棵View Tree只对应一个ViewRoot，它将和WindowManagerService进行一系列的通信，包括窗口注册、大小调整等（可以参见IWindowSession提供的接口方法）。那么，ViewRoot在什么情况下会执行这些操作呢？

主要的触发源有两种：

- View Tree内部的请求

比如某个View对象需要更新UI时，它会通过invalidate或者其他方式发起请求。随后这些请求会沿着View Tree层层往上传递，最终到达ViewRoot——这个View Tree的管理者再根据一系列实际情况来采取相应措施（比如是否发起一次遍历、是否需要通知WMS等）。

- 外部的状态更新

除了内部的变化外，ViewRoot同样可以接收来自外部的各种请求。比如WMS会回调ViewRoot通知界面大小改变、触摸事件、按键事件等。

不论是内部还是外部的请求，通常情况下ViewRoot并不会直接去处理它们，而是先把消息入队后再依次处理。ViewRoot内部定义了ViewRootHandler类来对这些消息进行统一处理。有意思的是，这个Handler实际上是和主线程的MessageQueue挂钩的，这也就验证了ViewRoot相关的操作确实是在主线程中进行的。正因为此，我们在ViewRootHandler中执行具体的事件处理时要特别注意不要有耗时的操作，否则很可能会阻塞主线程而引发ANR。

ViewRoot的工作流程可以概括如图11-9所示。

图中各种内外部请求和状态更新都首先入队到程序主线程的MessageQueue中，再由ViewRoot具体处理。这样做避免了应用程序因长

时间处理某个事件而导致的响应速度降低，我们在平时的项目研发中可以借鉴。

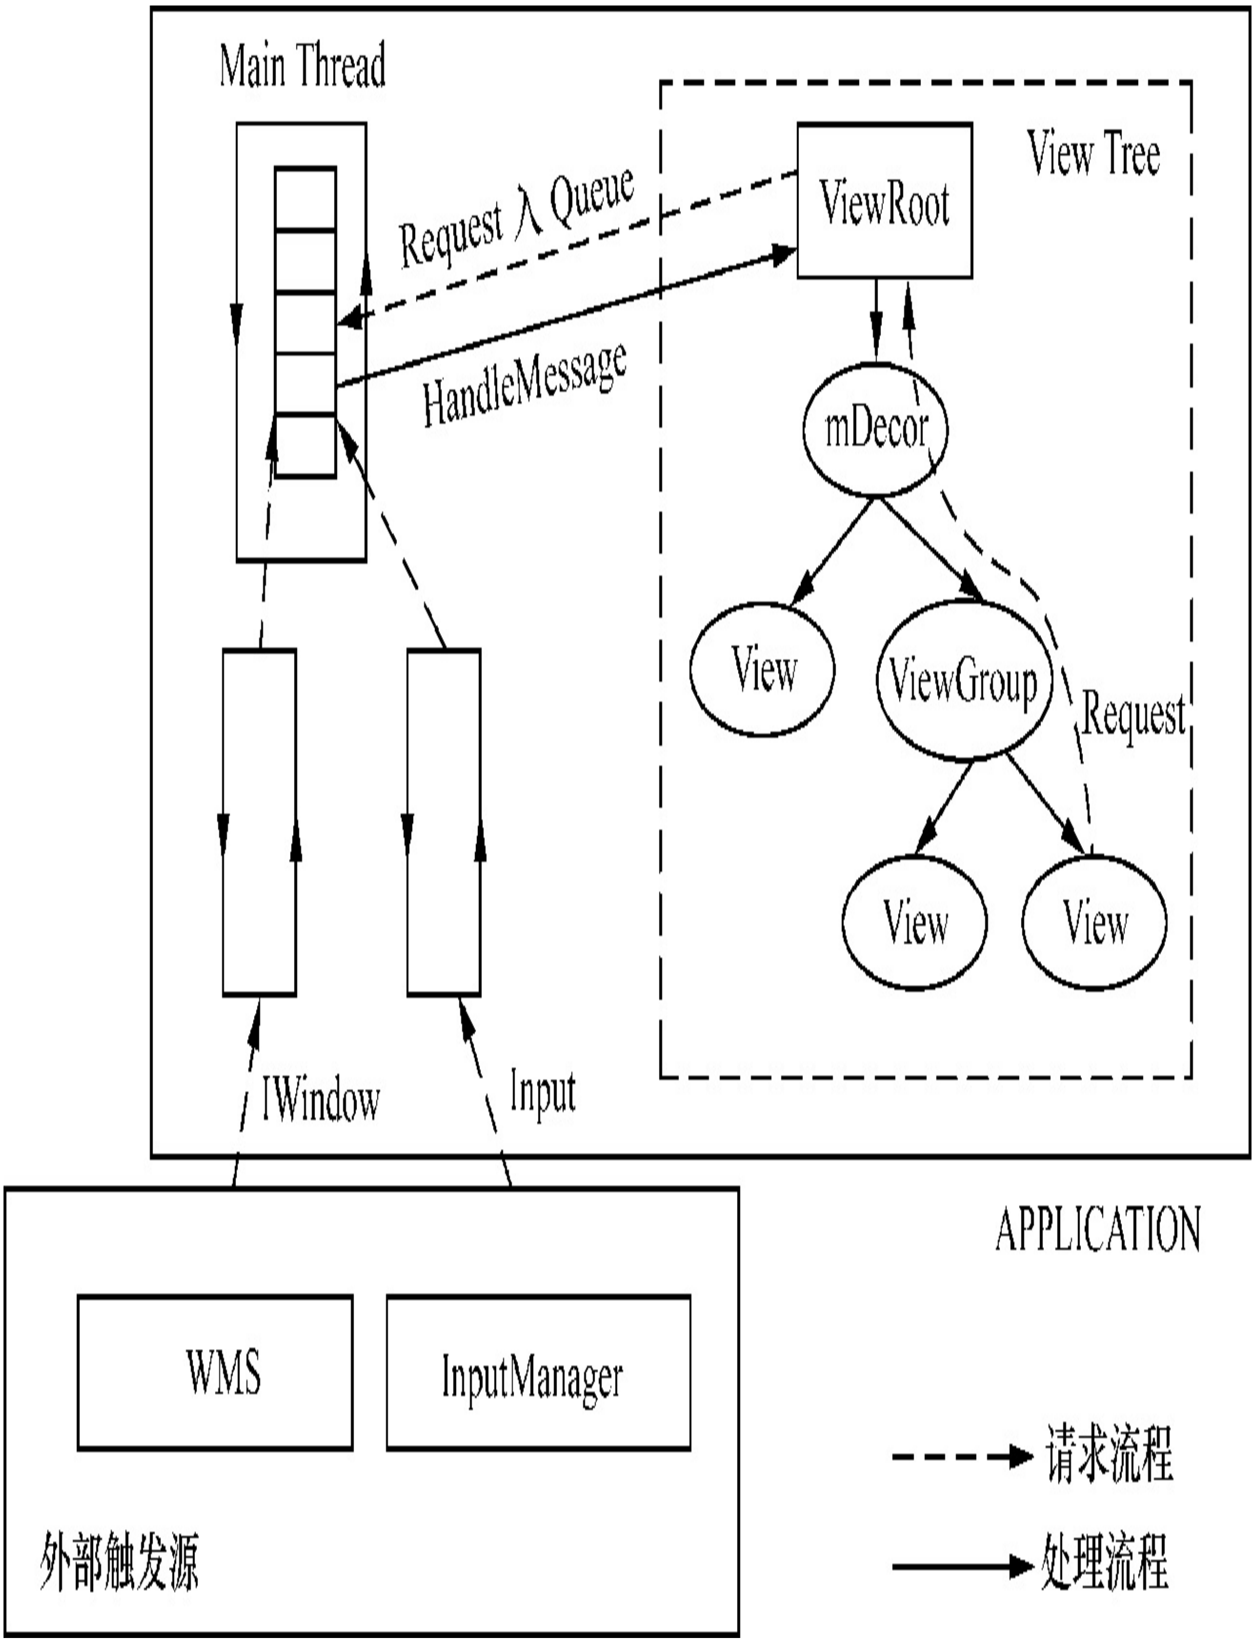

▲图11-9　ViewRoot的一般工作流程图

11.5 View Tree的遍历时机

所谓“遍历”（Traversal），是指程序按照一定的算法路径依次对一个集合（如View Tree）中的所有元素进行有且仅有一次访问的过程。相信学过数据结构的读者对此并不陌生。那么体现到Android的View体系中，“遍历”意味着什么呢？

先来思考以下两点：

- 父与子

我们知道，View Tree中的各元素是有“父子”关系的，即最顶层的元素是第二层元素（如果存在的话）的“父亲”，依此类推。

- 如何协调View Tree中所有元素的显示需求

如果整个UI界面只是由单一的View对象来描述的，那么很简单——它既可以占据整个屏幕空间；也可以有选择地在屏幕任何一片区域上显示。不过这种理想的情况是不存在的。通常我们面对的View树层级都较深，涉及的View对象数量众多。此时系统就要综合考虑各个View提出的“需求”了。比如它们都希望占据整个屏幕，或者都希望从（0,0）坐标点开始绘图，怎么办呢？Android的遍历机制则必须以尽可能公平的方式解决这些问题。

View体系中的“遍历”，简而言之就是系统综合考量各元素“请求”的过程。当“遍历”结束后，各个View元素就能得到系统的最终分配结果。Android系统要求所有元素都服从它的“安排”，否则很可能会产生未知的错误。从上面的分析可以知道，“分配结果”最少会包含两方面内容，即View对象的尺寸大小和位置——再加上View自身的UI内容，便构成了UI显示的三要素。我们将在后续小节详细分析整个遍历的过程。

在此之前还要解决一个问题：应用程序在什么情况下会遍历View Tree呢？

1．应用程序刚启动时

根据前面几个小节的分析，应用程序启动后会逐步构造出自己的整棵View Tree，然后进行一次全面的遍历：

```
public void setView(View view, WindowManager.LayoutParams attrs,
        // Schedule the first layout -before- adding to the windo
        // manager, to make sure we do the relayout before receiv
        // any other events from the system.//从注释中也可以看出这是第
    requestLayout();
```

在setView中调用的requestLayout就是执行第一次遍历的触发源。这个函数将通过向Choreographer注册一个CALLBACK_TRAVERSAL回调事件来间接驱动Layout的执行。最终的“遍历”工作由performTraversals来完成，我们放在后续小节统一分析。

2. 外部事件

对于应用程序来说，外部事件才是驱动ViewRoot工作的主要触发源。比如由用户产生的触摸、按键等事件，经过层层传递最终分配到应用进程中。这些事件除了可以改变应用程序的内部状态外，还可能影响到UI界面的显示——在必要的情况下，ViewRoot就会通过遍历来确定事件对各View对象产生的具体影响。

3. 内部事件

除了外来触发源，程序在自身运行的过程中有时也需要主动发起一些触发事件。比如我们写一个时钟应用，最少每隔一秒就需要刷新一次界面；又比如当一个View的Visibility从GONE到VISIBLE，都涉及界面的调整和重绘。所以程序在这些情况下要主动请求系统进行界面刷新，并可能引发遍历的执行。

下面先来举几个例子，看看ViewRoot在什么情况下会发起“遍历”。

1. View.requestLayout

View对象可以通过调用requestLayout()来主动申请遍历。这个函数的实现很简单，如下所示：

```
  /*frameworks/base/core/java/android/view/View.java*/
public void requestLayout() {…
```

```
        mPrivateFlags |= PFLAG_FORCE_LAYOUT;
        mPrivateFlags |= PFLAG_INVALIDATED;
        if (mParent != null && !mParent.isLayoutRequested()) {
            mParent.requestLayout();//把请求往上一层传递
        }
        …
    }
```

上述代码段首先置位View内部变量mPrivateFlags中的相关标志。在Android4.3系统中，View类中专门用于记录各种flag标志的变量就有3个，以满足不断增加的功能需求。PFLAG_ FORCE_LAYOUT表明这是程序自发的layout请求，它将在随后开展的遍历流程中产生作用。

接着主动发起遍历的View对象需要把这一请求提交给它的父亲（ViewParent），即mParent. requestLayout()。这个ViewParent既可能是ViewGroup，也可能是ViewRoot。前者没有重写requestLayout这个方法，所以会直接采用View类中的实现，即继续向上一级父类传递请求；而如果ViewParent是ViewRoot，则处理如下：

```
    public void requestLayout() {
        if (!mHandlingLayoutInLayoutRequest) {
            checkThread();//当前是否为主线程(即生成ViewRootImpl对象的纟
            mLayoutRequested = true;//当前已经发起Layout申请
            scheduleTraversals();//安排一次Traversal
        }
    }
```

第一行是检查当前是否为主线程——因为Android系统规定只有主线程才能够操作UI对象。这也确保了接下来的操作中不会出现多个线程同时访问的情况，因而不再需要特别的同步机制。第二行代码的mLayoutRequested用于表示当前是否已经有用户发起了Layout请求，这样如果再有第二个Layout请求到来就会被忽略掉。第三行我们将在后面统一分析。

2．View.setLayoutParams

这个方法用于设置一个View对象的各种布局属性：

```
    public void setLayoutParams(ViewGroup.LayoutParams params) {…
        requestLayout();
    }
```

也就是说，当View的布局发生变化时，它会主动申请一次遍历。如果mParent是ViewGroup，就会回调onSetLayoutParams通知父类进行相应的调整，然后直接调用前面分析过的requestLayout函数。

3．View.invalidate

“invalidate”从字面意思看是“使无效”，即将当前的UI界面判定为无效，从而引起重绘过程。要特别注意这个函数只能从UI 线程调用，其他线程则需要通过postInvalidate来实现同样的效果。

在View.java中，invalidate有多个带不同参数的函数实现。如下所示：

```
public void invalidate(Rect dirty);
public void invalidate(int l, int t, int r, int b);
public void invalidate();
void invalidate(boolean invalidateCache);
```

前两个函数所表达的意思相同，它们的参数都用于指定需要被“invalidate”的无效区域。只不过其中一个用Rect表示，另一个则用left，top，right和bottom表示。第三个函数则是最后一个函数的便捷实现，即invalidate(true)。

可见这几个函数形式各异，但基本思想是一样的。因而我们只挑选第一个函数来做具体分析：

```
    public void invalidate(Rect dirty) {
        if (skipInvalidate()) {//Invalidate是否合法？
            return;
        }
        if ((mPrivateFlags & (PFLAG_DRAWN | PFLAG_HAS_BOUNDS)) ==
            (PFLAG_DRAWN|PFLAG_HAS_BOUNDS)||(mPrivateFlags&PFLAG_
PFLAG_DRAWING_CACHE_VALID || (mPrivateFlags & PFLAG_INVALIDATED)
            mPrivateFlags &= ~PFLAG_DRAWING_CACHE_VALID;
            mPrivateFlags |= PFLAG_INVALIDATED;
            mPrivateFlags |= PFLAG_DIRTY;
            final ViewParent p = mParent;
            if (!HardwareRenderer.RENDER_DIRTY_REGIONS) {//是否需要
                if (p != null && ai != null && ai.mHardwareAccele
                    p.invalidateChild(this, null);
                    return;
                }
```

```
            }
            if (p != null && ai != null) {
               final int scrollX = mScrollX;
               final int scrollY = mScrollY;
               final Rect r = ai.mTmpInvalRect;
               r.set(dirty.left - scrollX, dirty.top - scrollY, d
               dirty.bottom - scrollY);
               mParent.invalidateChild(this, r);
           }
        }
    }
```

首先，skipInvalidate()用于判断是否要忽略这个invalidate操作，因为如果当前View并不是可见的，而且也不在执行动画，那么进行invalidate是没有意义。

接下来需要满足以下3个条件之一，才可以进行invalidate。

- mPrivateFlags中有PFLAG_DRAWN和PFLAG_HAS_BOUNDS标志

View中有3个PrivateFlags，即mPrivateFlags，mPrivateFlags2和mPrivateFlags3。其中每个变量最多支持32个标志，这些属性基本概括了整个View的特点。由于数量较多，我们只列出和分析相关的几个标志的含义。

PFLAG_DRAWN：当View表达出重绘意愿后，设这个bit为1，以保证invalidate的执行。

PFLAG_HAS_BOUNDS：这个View对象所占据的区域边界已经确认。

- 或者有PFLAG_DRAWING_CACHE_VALID标志。这个标志指明此View对象的cache是否也需要被invalidate，通常会在一个full invalidate中使用。
- 或者有PFLAG_INVALIDATED标志，这个标志用于指示我们是否需要重建View的display list。

紧接着函数会依次设置几个标志位，PFLAG_INVALIDATED表示我们调用了invalidate这个函数；PFLAG_DIRTY表示有相应的区域需要绘制。这些标志将在随后的ViewTree遍历过程中发挥作用。

RENDER_DIRTY_REGIONS表示是否只刷新dirty区域。当这个值为false时，就需要刷新整个区域；否则我们必须特别指明需要重新绘制的区域（即dirty区）。如果没有必要重绘整个区域，函数的最后将调用ViewParent.invalidateChild来进一步传递invalidate请求。

虽然ViewParent既有可能是ViewGroup，也有可能是ViewRoot，但沿着View Tree层层往上传递后，事件最终还是得由后者来处理，如图11-10所示。

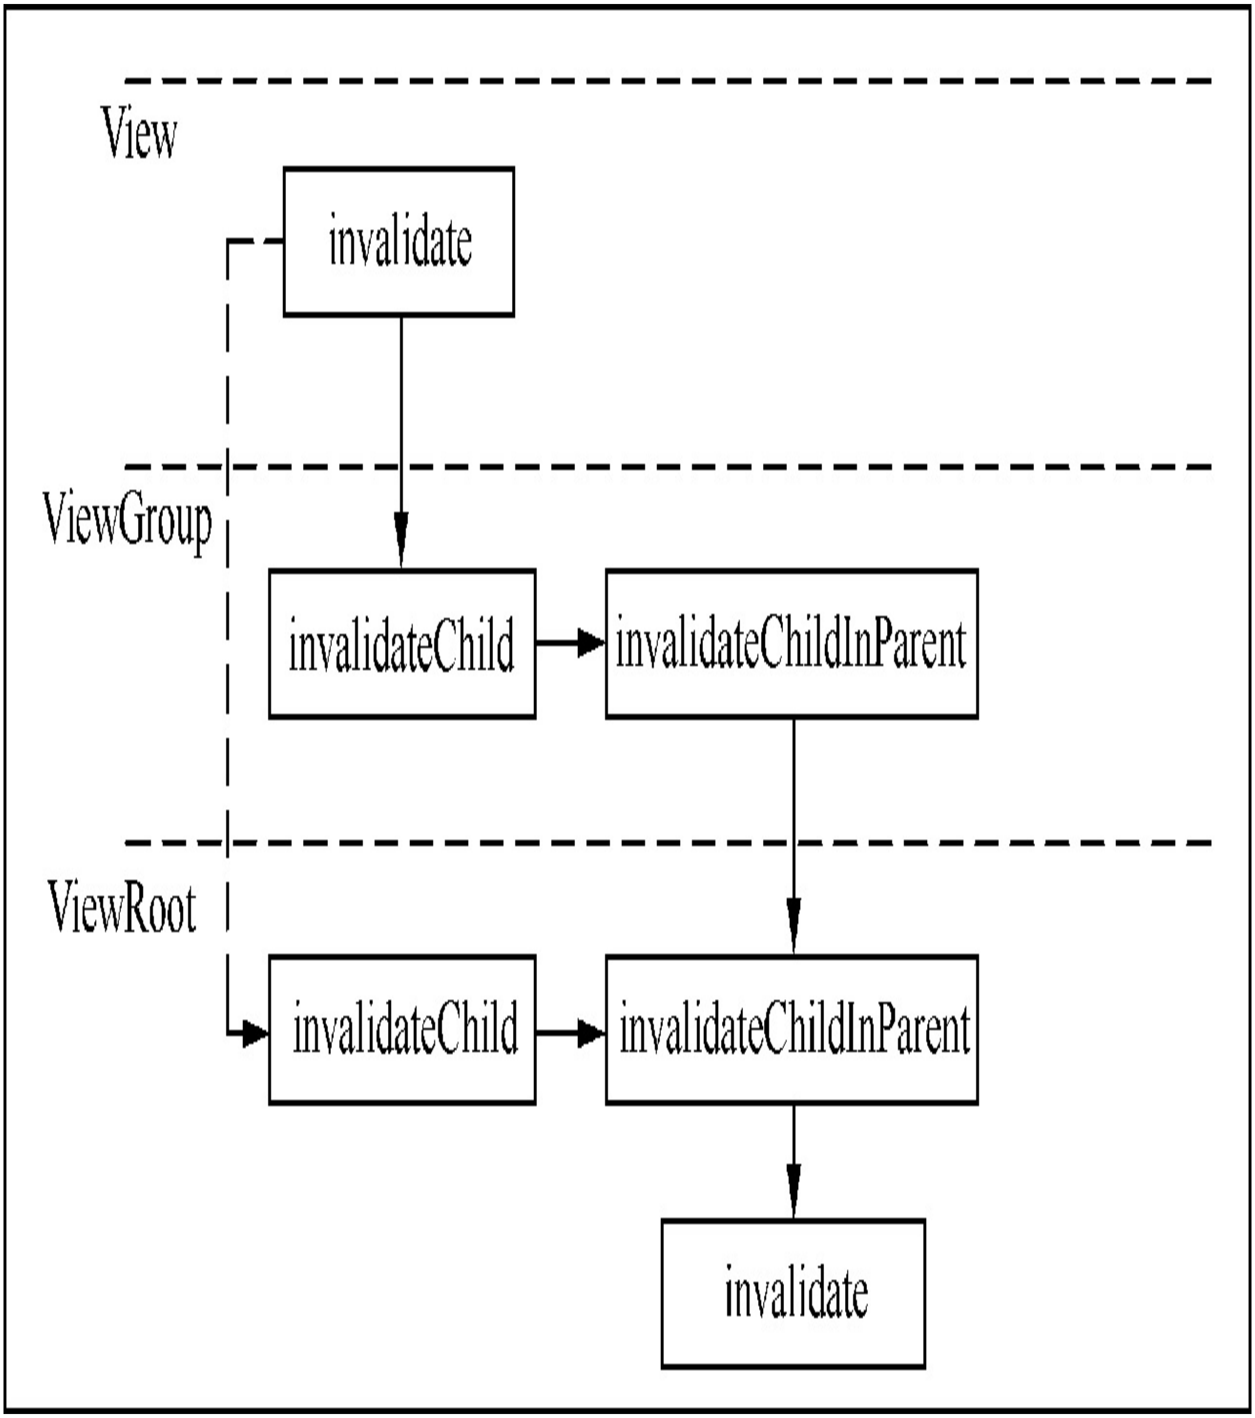

▲图11-10　invalidate函数的调用流程图

ViewGroup和ViewRoot中都拥有同名的invalidate Child，但它们所担负的责任却有很大的差异。前者是“从下而上”的，可以理解为从当前点开始，沿着ViewTree回溯收集dirty区（即需要重绘的区域）的过程；而后者则是“从上而下”的，它将真正发起ViewTree的遍历，从

而实现画面的重绘。

4．dispatchAppVisibility

当应用程序的可见性发生变化时（比如通过startActivity启动了一个新Activity，那么系统会通知前一个Activity它的可见状态发生了变化），会调用这个函数。

一旦ViewRootImpl收到Visibility改变的消息，也会组织一次Traversal。

通过这几个例子，我们不难发现——不论是外部还是内部事件，只要ViewRoot在处理过程中发现它可能引发UI界面的大小、位置等属性的变化，那么就很可能会执行“遍历”操作。遍历的主导者自然还是ViewRootImpl，因为只有它才能自上而下地管理整棵View Tree。

遍历流程的入口如下：

```
  /*frameworks/base/core/java/android/view/ViewRootImpl.java*
  void scheduleTraversals() {
    if (!mTraversalScheduled) {//当前是否已经在做遍历了
        mTraversalScheduled = true;
        …
        mChoreographer.postCallback(
                Choreographer.CALLBACK_TRAVERSAL, mTraversalR
        …
    }
}
```

变量mTraversalScheduled用于指示当前是否已经在做“Traversal”，以避免多次进入。整个函数的重点是mChoreographer.postCallback，在前面讲解WMS时曾多次看到过这个类——它是“Project Butter”项目的产物。如果对这部分内容有不清楚的地方，请参见SurfaceFlinger和WMS这两个章节。

一旦VSYNC信号来临，mTraversalRunnable中的run函数将被调用，以保证在最短的时间内有序地组织UI界面的更新。函数run的实现也很简单，它直接调用了doTraversal：

```
void doTraversal() {
    if (mTraversalScheduled) {
```

```
            mTraversalScheduled = false;//变量在这里就复位了
            …
            try {
                performTraversals();//执行遍历
            } finally {
                Trace.traceEnd(Trace.TRACE_TAG_VIEW);
            }
            …
        }
    }
```

可以看到，这个函数也并不是最终执行遍历的地方，还需要进一步调用performTraversals。后者的实现比较复杂，内容也很多，我们在后一小节将做专门的介绍。

图11-11描述了View体系中执行遍历的时机。

11.6 View Tree的遍历流程

上一小节说过，UI显示的3要素是尺寸大小、位置和内容，它们在遍历过程中分别对应以下3个函数：

- performMeasure（尺寸大小）

  用于计算View对象在UI界面上的绘图区域大小。

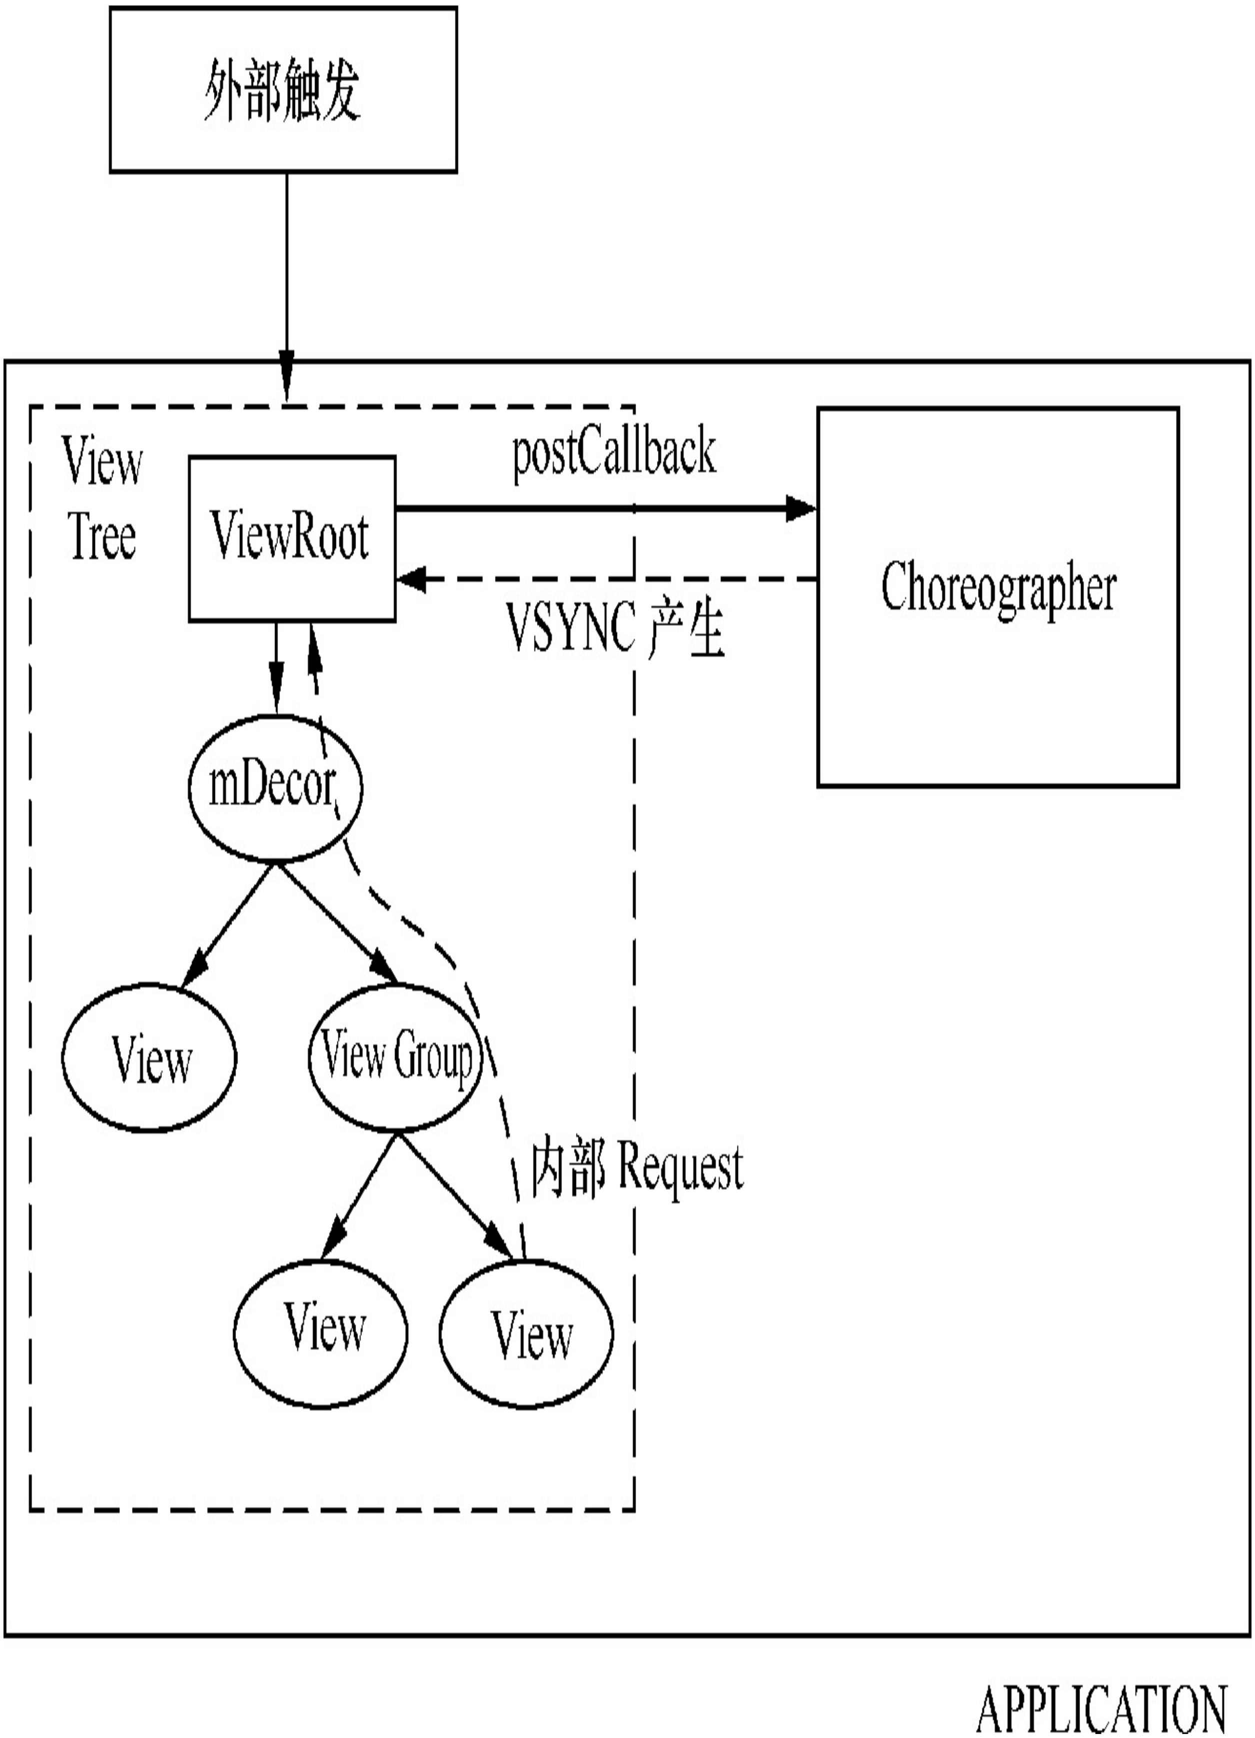

外部触发
View
Tree
ViewRoot
postCallback
Choreographer
VSYNC 产生
mDecor
View
View Group
内部 Request
View
View
APPLICATION

▲图11-11　遍历的执行时机

- performLayout（位置）

　　用于计算View对象在UI界面上的绘图位置。

- performDraw（绘制）

　　上述两个属性确定后，View对象就可以在此基础上绘制UI内容了。

　　遍历的主体是performTraversals。这个函数虽然长达七百多行，但整体逻辑就是按照上述3个步骤进行的。分析时一定要抓住这个线索，才不容易偏离主体，如图11-12所示。

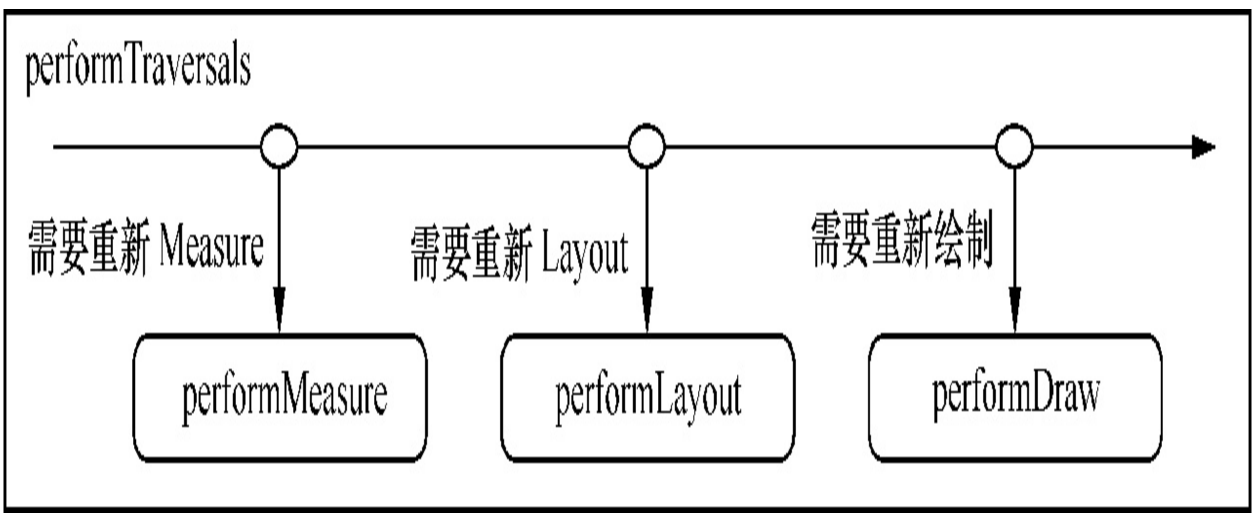

▲图11-12　performTraversals的实现主体

　　所以接下来的重点就转换为：在什么条件下需要执行以上3个动作？

　　首先来介绍几个全局变量的含义，如表11-1所示。

表11-1　performTraversals中涉及的部分重要变量

变　量　名	含　　义

MView（或者host）	mView是该ViewRoot管理下View Tree的根节点。函数在执行过程中需要频繁使用到这个变量，为了避免意外的篡改，performTraversals函数开头使用了一个本地变量host来指向它，后面的操作全部由这个变量完成
mFirst	判断是否第一次执行performTraversals
mIsInTraversal	当前是否在执行Traversal
mFullRedrawNeeded	在某些情况下，我们需要重绘所有界面，这个变量将影响后续的performDraw
mLayoutRequested	在很多情况下，mLayoutRequested都会被置为true，如View对象主动发起一个requestLayout；第一次调用performTraversals；当前的宽高（mWidth/mHeight）和期望的值（由mWinFrame记录）不符合等
mWinFrame	由WMS计算后得出的Frame
mFitSystemWindowsInsets	设置内边距的初始值，以容纳包括状态栏、输入法等在内的系统窗口
	当View被attached到Window时，用于

mAttachInfo	记录一系列相关信息。比如其中的：mContentInsets，表示View中除screen decoration外的空间；mWindowVisibility，表示Window的可见性；mSystemUiVisibility，表示通过setSystemUiVisibility所设置的系统ui的各标志位等
mWidth/mHeight	通过主动请求WMS计算后得到的值。要特别注意它们和desiredWindowWidth/desired WindowHeight的区别，后面这组值与mWinFrame中保存的值是一致的，表示WMS期望的应用程序的宽/高
sWindowSession	ViewRoot与WMS的通信接口

接下来我们需要寻找一条线索来贯穿这个长函数。由于代码量较大，涉及的变量也很多，“一个猛子扎进代码”的效果并不好——因而建议采取“反推”的方式。我们真正关心的是：在什么条件下程序会分别执行遍历的上述3个步骤，具体又是如何执行的？所以只要先找到调用这3个函数的地方，再往上推导与之相对应的变量及处理过程，整个流程就明朗多了。后续一旦梳理了函数的逻辑框架，再来尝试正面分析源码，相信会有另一番收获。

1．performMeasure

这个函数第一次被调用的地方在ViewRootImpl.java的第1668行（另外一个调用地方也是类似的，读者可以自行分析）。外围条件是：

```
private void performTraversals() {…
   if (mFirst || windowShouldResize || insetsChanged ||viewVi
   null) {//层级1
      …
      if (!mStopped) {//层级2
```

```
boolean focusChangedDueToTouchMode = ensureTouchMod
 (relayoutResult&WindowManagerImpl.RELAYOUT_RES_IN_
if (focusChangedDueToTouchMode || mWidth != host.ge
       || mHeight != host.getMeasuredHeight() || co
   int childWidthMeasureSpec = getRootMeasureSpec(m
   int childHeightMeasureSpec = getRootMeasureSpec(
   // Ask host how big it wants to be
   performMeasure(childWidthMeasureSpec, childHeigh
   …
```

用于判断是否执行performMeasure的条件变量都高显出来了。其中既有“与”的情况，也有 “或”的情况，分别组成了3个层级，如表11-2所示。

表11-2　执行performMeasure的条件

Level	Member	Description
层级1	mFirst	第一次调用performTraversals
	windowShouldResize	见Case 1.1
	insetsChanged	WMS要求的content insets和当前值不一致时，为true
	viewVisibilityChanged	ViewRootImpl记录的Visibility和ViewTree根节点所记录的值产生差异时，说明可见性有变化；或者需要为这个窗口产生一个新的Surface，那么这个变量是true
	params	这棵View Tree的WindowManager.LayoutParams属性值。应用程序可以通过多种方法来设置，如Window.setAttributes
层级2	mStopped	当Activity处于stop状态时，其对应的Window也同样会被stopped
	focusChangedDueToTouchMode	TouchMode是否引起focus的变化

层级3	mWidth != host.getMeasuredWidth()	getMeasuredWidth()是View对象经过onMeasure后测量出来的宽度
	mHeight != host.getMeasuredHeight()	getMeasuredHeight()是View对象经过onMeasure后测量出来的高度
	contentInsetsChanged	和insetsChanged表达的含义相同

```
Case 1.1 (windowShouldResize):
boolean windowShouldResize = layoutRequested && windowSizeMayChan
&& ((mWidth != host.getMeasuredWidth() || mHeight != host.getMeas
              || (lp.width == ViewGroup.LayoutParams.WRAP_CONTENT
                     frame.width() < desiredWindowWidth && frame.
              || (lp.height == ViewGroup.LayoutParams.WRAP_CONTEN
frame.height() < desiredWindowHeight && frame.height() != mHeight
```

如果mLayoutRequested为true，并且当前不处于stopped状态，那么layoutRequested为true。变量windowSizeMayChange正如其名所示，表明窗口的尺寸大小有可能发生变化——比如当前宽高与期望值不相符。假设当前有layout需求，并且window size确实需要改变，那么windowShouldResize就是true。

一旦上述3个层级的条件都满足，程序就开始执行performMeasure。实际上这个函数什么也没做，只是简单地调用了View Tree顶层元素的measure函数：

```
mView.measure(childWidthMeasureSpec, childHeightMeasureSpec);
```

这样ViewRootImpl就将控制权转交给View树的根元素，真正的Traversal才刚刚开始。顺便说一下，View类中提供了measure和onMeasure两个函数实现。建议读者在扩展一个新的View组件时，尽量不要直接重载measure方法，而是通过改写后者来达到相同的目的。真正的测量工作也是在onMeasure中进行的，如下：

```
    protected void onMeasure(int widthMeasureSpec, int heightMeas
       setMeasuredDimension(getDefaultSize(getSuggestedMinimumWid
             getDefaultSize(getSuggestedMinimumHeight(), heightMe
    }
```

参数中的widthMeasureSpec和heightMeasureSpec是该View对象的上一级父对象要求的宽高值——如此层层而下传递到View Tree中的各个元素。View Tree的树根元素（即mDecor）的这两个值是由ViewRootImpl传入的，后者通过MeasureSpec.makeMeasureSpec来生成符合当前要求的spec。每一个spec（int类型值）的格式如下：

mode（最高二位）+size

通过MeasureSpec.getMode和MeasureSpec.getSize可以分别获得一个spec值中的mode和size。其中mode有3种。

UNSPECIFIED=0：父对象没有强制要求子对象必须遵循哪些约束。

EXACTLY= 1：父对象要求子对象必须严格按照它给定的值来约束自己。

AT_MOST= 2：子对象可以自行选择给定范围内的值。

mode的选取则和LayoutParams有一定关联。比如MATCH_PARENT对应的是EXACTLY；WRAP_CONTENT对应的是AT_MOST。

虽然View.java提供了默认的onMeasure实现，但是扩展的视图对象通常有自己需要考虑的因素，所以它们会选择重载这个函数来切合自己的需求。比如mDecor是一个FrameLayout，其onMeasure源码如下：

```
/*frameworks/base/core/java/android/widget/FrameLayout.java*/
@Override //这是一个重载函数
protected void onMeasure(int widthMeasureSpec, int heightMeas
    int count = getChildCount();//子对象个数
    /*Step1. 判断父对象的mode要求*/
    final boolean measureMatchParentChildren =
            MeasureSpec.getMode(widthMeasureSpec) != MeasureS
            MeasureSpec.getMode(heightMeasureSpec) != Measure
    mMatchParentChildren.clear();
    int maxHeight = 0;//所有子对象中测量到的最大高度
    int maxWidth = 0;//所有子对象中测量到的最大宽度
    int childState = 0;

    for (int i = 0; i < count; i++) {//循环处理所有子对象
        final View child = getChildAt(i);//获取一个子对象
        if (mMeasureAllChildren || child.getVisibility() != G
           measureChildWithMargins(child, widthMeasureSpec, 0
```

```
                                              0);//Step2.
            final LayoutParams lp = (LayoutParams) child.getL
            /*Step3. 取得最大值*/
           maxWidth = Math.max(maxWidth, child.getMeasuredWid
                           lp.leftMargin + lp.rightMargin);
           maxHeight = Math.max(maxHeight,child.getMeasuredHe
                                lp.topMargin + lp.bottomMargi
           childState = combineMeasuredStates(childState, chi
            …
        }
    }

    /*Step4. 综合考虑其他因素 */
    // 检查padding
    maxWidth += getPaddingLeftWithForeground() + getPaddingRi
    maxHeight += getPaddingTopWithForeground() + getPaddingBo

    // 检查建议的最小宽高值
    maxHeight = Math.max(maxHeight, getSuggestedMinimumHeight
    maxWidth = Math.max(maxWidth, getSuggestedMinimumWidth())

    // 检查foreground背景宽高值
    final Drawable drawable = getForeground();
    if (drawable != null) {
        maxHeight = Math.max(maxHeight, drawable.getMinimumHe
        maxWidth = Math.max(maxWidth, drawable.getMinimumWidt
    }
    /*记录结果*/
    setMeasuredDimension(resolveSizeAndState(maxWidth, widthM
                 childState),resolveSizeAndState(maxHeight, h
                    childState << MEASURED_HEIGHT_STATE_SHIFT
    …
}
```

先给大家介绍下padding和margin的基础知识——对于View类而言，它只有padding，没有margin。这是因为padding指的是“内容”区域与外围边框的距离，分为left、right、top、bottom四个方向。而margin则是“内容”内部的进一步细化——即“内容”中各元素之间的间距。可想而知，一个View（非ViewGroup）实例的“内容”本身就是不可分割的，不存在内部对象间距的说法。而ViewGroup由多个子对象组成，它们之间有时需要margin属性来将彼此区分开来。更多详细描述可以参见后续小节对于View和ViewGroup的属性分析。

Step1@onMeasure。通过MeasureSpec.getMode可以取得父对象对当前视图的要求，只要宽或者高有一个不是EXACTLY，那么FrameLayout在

后续都需要执行match parent的操作。

Step2@onMeasure。变量count代表该FrameLayout中包含的子对象数量，它们都记录在成员变量ViewGroup. mChildren中。基于View Tree的特性，我们需要逐个处理这些子对象。这里使用的是measureChildWithMargins，意即需要考虑padding和margins。这个函数将根据padding和margin来生成新的spec，然后调用child. measure函数。于是遍历流程就到了子对象中。后者如果也是ViewGroup，通常还会重载onMeasure，进一步把测量指令往下“递归”，直到叶节点。当然，并不是所有子对象都需要被测量。假如View本身的可见性是GONE，而且变量mMeasure AllChildren为false（可以在android:measureAllChildren中配置），那么程序会跳过这个对象。

Step3@onMeasure。通过测量，我们可以得到child的计算结果，即child.getMeasuredWidth()和child.getMeasuredHeight()。这两个函数分别对应的是View. mMeasuredWidth和View.mMeasured Height成员变量，它们通常是在onMeasure结束时通过setMeasuredDimension来设置的。对于我们自己扩展的View组件，一定要注意这一点。

FrameLayout需要知道各子对象中的最大宽高值，计算公式如下：

```
maxWidth = Math.max(maxWidth,child.getMeasuredWidth() + lp.leftMa
maxHeight = Math.max(maxHeight, child.getMeasuredHeight() + lp.to
```

maxWidth/maxHeight记录的是当前测量出的最大值。如果后续子对象的测量结果超过前一次的最大值，那么就做一下替换。

Step4@onMeasure。上述步骤得出了子对象中的最高和最宽值，但并不是最终结果。还有3个因素可能产生影响：

- padding

  ViewGroup本身的padding也是需要考虑的。

- 最小宽高值

  getSuggestedMinimumHeight用于计算适应当前View的最小高度值，核心语句如下：

```
return (mBackground == null) ? mMinHeight : max(mMinHeight, mBack
```

mBackground是背景图片；mMinHeight则是通过android: minHeight设置的值，表示开发者希望这个View对象获取到的最小高度值。

getSuggestedMinimumWidth的实现也类似。

- foreground的宽高值

对应的是mForeground所指示的背景，不一定存在。

Step5@onMeasure。如前所述，onMeasure的计算结果需要被记录下来，以便后续操作时查询使用。值得一提的是，mMeasuredWidth和mMeasuredHeight保存的不仅仅是size，还有state。所以还要先调用resolveSizeAndState来对这两个值进行格式整合，最后才能通过setMeasuredDimension来记录。具体格式读者可以通过阅读源码获悉，这里不予详述。

2．performLayout

经过上面的performMeasure，View Tree中各元素的大小已经基本确定下来，并保存在自己的内部成员变量中。接下来，ViewRootImpl会进入另一个“遍历”过程，即位置测量。Layout这个词在设计领域的释义类似于“构图”、“布局”，因而它既需要“大小”，也需要“位置”信息。函数performMeasure得到的便是对象的尺寸大小，而performLayout更确切地说是在此基础上进一步完善“位置”信息，然后组合成真正的“layout”。Android官方文档有这样的描述：

“Layout is a two pass process: a measure pass and a layout pass. The measuring pass is implemented in measure(int, int) and is a top-down traversal of the view tree… The second pass happens in layout(int, int, int, int) and is also top-down. During this pass each parent is responsible for positioning all of its children using the sizes computed in the measure pass.”

也就是说，Layout=measure pass+layout

pass=measure()+layout()onMeasure+onLayout

这多少有点文字游戏的味道，我们在实际工作中发现很多开发者并没有搞清楚，从而引发了理解上的混乱。

函数performLayout在performTraversals中的调用位置只有一处，即Line 1730行。我们仍然沿用前面的方法，看看与之相关的执行条件：

```
    private void performTraversals() {…
        final boolean didLayout = layoutRequested && !mStopped;
        …
        if (didLayout) {
        performLayout();
           …
```

变量didLayout取决于两个因素，即layoutRequested和mStopped——其中后者已经分析过，此处不再赘述。而layoutRequested主要由下面的语句赋值：

```
boolean layoutRequested = mLayoutRequested && !mStopped
```

成员变量mLayoutRequested为true的情况比较多，我们在前面专门介绍过，读者可以回头看看。

简而言之，一旦ViewRootImpl发现需要执行layout，那么它会调用performLayout进行位置测量。具体实现与performMeasure基本一致，只是间接调用了View Tree的顶层根元素（mView）的layout：

```
private void performLayout() {…
        final View host = mView;
        …
        try {
            host.layout(0, 0, host.getMeasuredWidth(), host.getMe
        } …
    }
```

我们仍然以FrameLayout为例来看看View对象是如何计算layout的：

```
/*frameworks/base/core/java/android/view/View.java*/
public void layout(int l, int t, int r, int b) {…
```

```
        boolean changed = isLayoutModeOptical(mParent) ?
               setOpticalFrame(l, t, r, b) : setFrame(l, t, r, b);
        if (changed||(mPrivateFlags & PFLAG_LAYOUT_REQUIRED) == PF
             onLayout(changed, l, t, r, b);//执行layout
             …
         }
         mPrivateFlags &= ~PFLAG_FORCE_LAYOUT;
     }
```

上面这个函数的l、t、r、b分别代表此View对象与父对象的左、上、右、下边框的距离。和measure的很大差异，是layout直接将这些值记录（setFrame）到成员变量中，即mLeft，mTop，mRight和mBottom。接下来，如果changed为true，则意味着本次设置的边距与上一次相比发生了变化；或者flags中强制要求layout，那么就会调用onLayout。既然该View对象本身的layout已经确定下来，可以猜想到这个函数应该是对其子对象进行布局调整的过程。也正因如此，View类中的onLayout函数实现体是空的——这就要求各ViewGroup的扩展类，如FrameLayout需要重载并具体实现它们所需的功能：

```
/*frameworks/base/core/java/android/widget/FrameLayout.java*/
    @Override//这是个重载函数
    protected void onLayout(boolean changed, int left, int top, i
        final int count = getChildCount();//子对象的个数

        final int parentLeft = getPaddingLeftWithForeground();//这
        final int parentRight = right - left - getPaddingRightWit
        final int parentTop = getPaddingTopWithForeground();
        final int parentBottom = bottom - top - getPaddingBottomW
        …
        for (int i = 0; i < count; i++) {//循环处理所有子对象
            final View child = getChildAt(i);//当前子对象
            if (child.getVisibility() != GONE) {//如果为GONE的话，表
                final LayoutParams lp = (LayoutParams) child.getL
                设置的layout属性
                final int width = child.getMeasuredWidth();//chil
                final int height = child.getMeasuredHeight();//ch

                int childLeft;//最终计算出的child的左边距
                int childTop;//最终计算出的child上边距

                int gravity = lp.gravity;//这个属性值是后面计算的依据
                …
                final int layoutDirection = getResolvedLayoutDire
                final int absoluteGravity = Gravity.getAbsoluteGr
                Direction);
```

```
                final int verticalGravity = gravity & Gravity.VER

                switch (absoluteGravity & Gravity.HORIZONTAL_GRAV
                    case Gravity.LEFT:
                        childLeft = parentLeft + lp.leftMargin;
                        break;
                    case Gravity.CENTER_HORIZONTAL://后面以此为例做讠
                        childLeft = parentLeft + (parentRight - p
                        lp.leftMargin - lp.rightMargin;
                        break;
                    case Gravity.RIGHT:
                        childLeft = parentRight - width - lp.righ
                        break;
                    default://default情况下的处理，应用开发人员要特别留
                        childLeft = parentLeft + lp.leftMargin;
                }
                …//省略childTop的计算过程，和childLeft是类似的
                child.layout(childLeft, childTop, childLeft + wid
            }
        }
    }
```

进入代码分析前，先来思考下FrameLayout的onLayout需要解决的问题。FrameLayout与其他几种常用布局方式如LinearLayout，GridLayout的一个显著区别是，它的各子对象并不存在“竞争空间”的问题。换句话说，FrameLayout中的元素是“层叠”而成的，它们的位置主要取决于自身与父对象间的调整。明白这个道理后，我们再来看看上面的onLayout源码实现。

和onMeasure类似，它首先计算所包含子对象的个数，然后通过for循环逐个处理。每次循环的最后一行都调用了child.layout，由此传入的4个参数就是此child的layout信息。我们的关注重点就转化为：这几个参数是如何得到的呢？

首先要知道，一个长方体的layout只需要left，top和width，height就可以确定下来了——后两者在measure中已经有了确切的结果，所以最终的问题就转化为对left和top的计算。

进行过应用开发的读者应该知道，我们可以在View对象中设置Gravity属性来控制其在父对象中的位置，如表11-3所示。

表11-3　Gravity常用属性释义

Gravity Attributes	Description
TOP	不改变尺寸大小的情况下，放置在父对象的头部
BOTTOM	不改变尺寸大小的情况下，放置在父对象的尾部
LEFT	不改变尺寸大小的情况下，放置在父对象的左部
RIGHT	不改变尺寸大小的情况下，放置在父对象的右部
CENTER_VERTICAL	不改变尺寸大小的情况下，放置在父对象的垂直方向中部
CENTER_HORIZONTAL	不改变尺寸大小的情况下，放置在父对象的水平方向中部
CENTER	不改变尺寸大小的情况下，放置在父对象的正中部位

下面以mLeft在Gravity.CENTER_HORIZONTAL情况下的处理过程为例来做详细讲解。为了让读者看得更清楚些，同时假设lp.leftMargin和lp.rightMargin为0：

```
childLeft = parentLeft + (parentRight - parentLeft - width) / 2 +
        =parentLeft + (parentRight - parentLeft - width) / 2;
```

各变量含义如图11-13所示。

根据上图，parentRight-parentLeft得到的是方框2，即FrameLayout内容区域的宽度。因为子对象是要放置在这里的，其“center”的中心也是以图中的中轴线为标准。所以（parentRight-parentLeft－ width）／2得到的是方框3左边线与方框2对应边线的距离，最终childLeft还要在此基础上加parentLeft。

计算出childLeft，程序下一步将按照类似的方法得出childTop。我们说过，对于一个长方形来说，left+top+width+height已经足够确认它的layout了。因而调用

```
child.layout(childLeft, childTop, childLeft + width, childTop + h
```

来设置子对象的layout区域。

如此循环往复，直到View Tree中所有元素都处理完成。

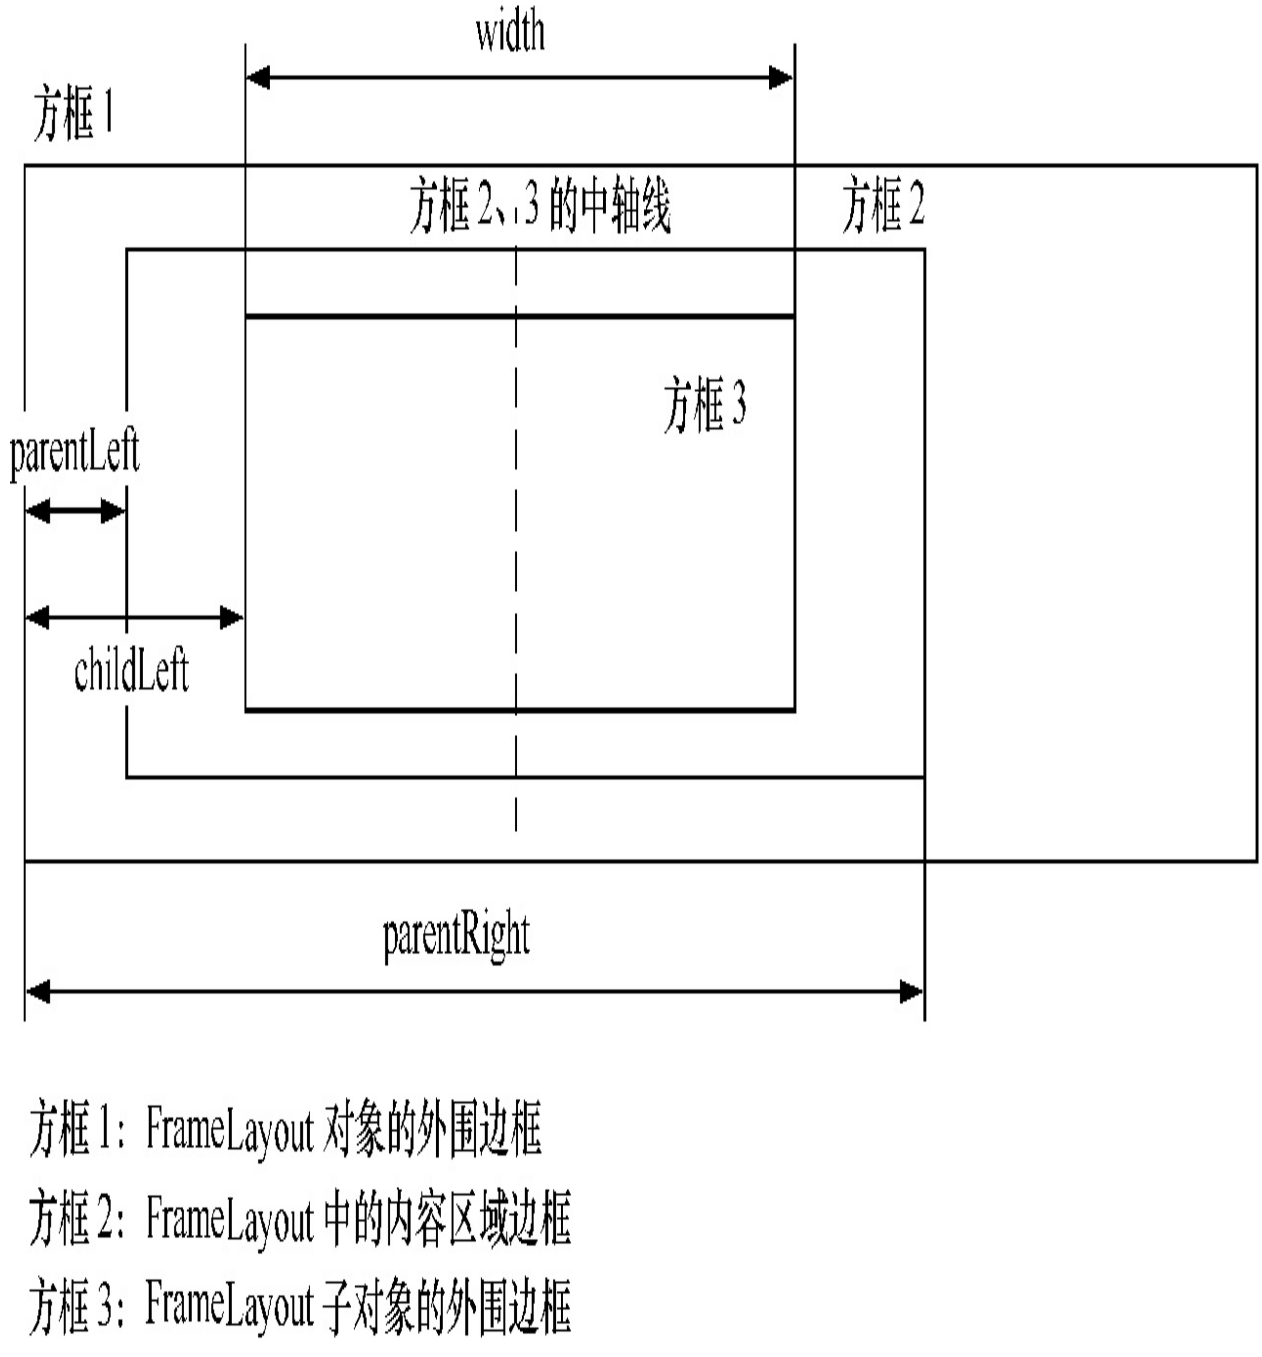

▲图11-13　childLeft计算过程中涉及的变量释义图

3．performDraw

一个对象的layout确定后，它才能在此基础上执行“Draw”。函数performDraw是遍历流程中最后被调用的，将在“画板”上产生UI数据，然后在适当的时机由SurfaceFlinger进行整合，最终显示到屏幕

上。绘制UI的实现核心如下：

- Surface

可以把Surface比作“画板”。“巧妇难为无米之炊”，假如没有合法的Surface，UI数据就无法正常存储与显示。

- 图形绘制的方式

有两种，即硬件和软件。

- View Tree各元素的协调关系

我们将按照怎样的顺序来绘制UI呢？

performDraw在进行必要的判断（performDraw的判断条件比较简单，读者可以自行分析）后，将接着调用draw；后者则根据hardware/software render的配置，选择调用attachInfo.mHardwareRenderer.draw或者drawSoftware来执行具体的绘制操作。

本小节的侧重点是软件渲染方式，具体如下所示：

```
/*frameworks/base/core/java/android/view/ViewRootImpl.java*/
private boolean drawSoftware(Surface surface, AttachInfo atta
        boolean scalingRequired, Rect dirty) {…//dirty表示需要
    Canvas canvas;//后续小节有详细介绍
    try {…
        canvas = mSurface.lockCanvas(dirty);//先取得一个Canvas
        …
    } catch (Surface.OutOfResourcesException e) {
        …
    } catch (IllegalArgumentException e) {
        …
    }

    try {…
        try {
            canvas.translate(0, -yoff);//坐标变换
            if (mTranslator != null) {
                mTranslator.translateCanvas(canvas);
            }
            …
```

```
                mView.draw(canvas);//由顶层元素开始遍历绘制
            } finally {…
            }
        } finally {
            try {
                surface.unlockCanvasAndPost(canvas);//绘制完毕，释放
            } catch (IllegalArgumentException e) {…
            }
        }
        return true;//true表示成功
    }
```

这个函数的实现步骤如下。

（1）lockCanvas。Canvas的底层实现仍然是Surface，它是面向应用层开发的“画板工具”，我们在后面小节有专门介绍。在使用Canvas前，必须显式地锁定它，然后才可以正常使用。假如lock过程中出现任何异常，那么drawSoftware都将失败，并返回false。

（2）坐标变换。包括由入参传入的yoff组成的坐标平移，以及mTranslator指示的变换（如果存在的话）。

（3）View.draw。这是真正绘制UI的地方，后续我们会重点分析。

（4）unlockCanvasAndPost。到目前为止我们改变的还只是本地数据，只有把draw完成后的Canvas信息透过Surface提交给SurfaceFlinger，并由后者统一合成渲染到Framebuffer中，才能最终把界面显示到屏幕上。

这样就分析完成了performTraversals中的三大支柱，即performMeasure、performLayout及performDraw。它们按照顺序执行View Tree中各元素的大小遍历、位置遍历以及绘图遍历，从而把每个View对象所代表的UI信息正确地绘制到了终端屏幕上——它们的实现流程“大同小异”，即通过递归的方式，由上而下遍历和处理View Tree中的对象（只是具体的处理手段和目的不同）。

对于performDraw的内部实现，因为还涉及Canvas，View/ViewGroup属性、坐标变换等一系列技术细节，所以特别把它们独立出来，在接下来的小节中逐一击破。

11.7 View和ViewGroup属性

相信不少应用开发者都有类似的经历：在用XML文件进行UI布局时，无论怎么调整都达不到预期的界面效果；看着一堆padding属性值，辨别不出它们的差异，无从下手；原本运行很好的一个UI程序，只是改动了布局文件中一个很小的地方，整个界面就出现了严重变形。出现这些情况主要有两方面的原因：其一是我们对View的属性还不够熟悉，无法掌握它们所表达的确切意思，只能通过反复调整试验来达到目标。其二就是对View的内部实现不够了解。“工欲善其事，必先利其器”，只有对View的“外在”和“内在”都有了更全面的认识，再来做应用开发才能得心应手。

为此，我们将专门在本小节讲解View和ViewGroup中的一些关键属性，希望能让读者对它们有个感性而深入的认识。

值得一提的是，View的两个重要特性就是它既负责UI显示，也可以进行各种事件的处理——这同时也是它和Drawable的一个本质区别。

11.7.1 View的基本属性

相信有不少读者在阅读源码时，都会被View类中数量众多的成员变量所困扰——特别是对于那些名称相近的变量更是如此。另外，View对象中部分成员变量的值是可以通过在layout(xml)文件中指定View属性来改变的。所以属性名与变量之间的对应关系也是一个重点，我们在本小节一并详细列出，以方便读者阅读学习。

View中与UI显示相关的属性如表11-4所示。

表11-4 View中的UI属性

<table>
<tr><td>UI属性</td><td colspan="2">相关方法与布局属性</td></tr>
<tr><td rowspan="2">Identifier</td><td>相关方法</td><td>setId(int)
findViewById()</td></tr>
<tr><td>布局</td><td></td></tr>
</table>

	属性	android:id
Tag	相关方法	getTag() findViewWithTag(Object tag)
	布局属性	android:tag
Position	相关方法	getLeft(),getTop(),getRight(), getBottom() setLeft(int left)， setTop (int top)， setRight(int right)， setBottom(int bottom)
	布局属性	无
Size	相关方法	setMinimumWidth(int) setMinimumHeight(int)
	布局属性	android:minWidth android:minHeight android:layout_width android:layout_height

Padding	相关方法	setPadding(…),setPaddingRelative(…), getPaddingLeft(),getPaddingTop() getPaddingStart(),getPaddingEnd()等
Padding	布局属性	android:padding android:paddingLeft android:paddingRight android:paddingTop android:paddingBottom android:paddingStart android:paddingEnd
Margin	相关方法	
	布局属性	
	相关方法	setGravity(int)

Gravity	布局属性	android:gravity 可以设置的值包括：top，bottom，left，right，center_vertical，center_horizontal，center等，可以参考官 档说明： http://developer.android.com/reference/android/R.attr.html#g
Visibility	相关方法	setVisibility(int),getVisibility()

	布局属性	android:visibility
ScrollBar	相关方法	setScrollBarSize() setScrollBarStyle()
	布局属性	android:scrollbars android:scrollX android:scrollY android:scrollbarSize android:scrollbarStyle等
Background	相关方法	setBackgroundResource(int)
	布局属性	android:background
Effect	相关方法	getVerticalFadingEdgeLength() setAlpha(float)
	布局属性	android:fadeScrollbars android:fadingEdgeLength android:alpha
		setRotation(float)

Transform	相关方法	setRotationX(float) setRotationY(float) setScaleX(float) setScaleY(float) setPivotX(float) setPivotY(float) setTranslationX(float) setTranslationY(float)
	布局属性	android:rotation android:rotationX android:rotationY android:scaleX android:scaleY android:transformPivotX android:transformPivotY android:translationX android:translation

下面从源码角度详细分析表中的一些重要属性。

1．Position

View.java中与此相关的内部变量是：

```
protected int mLeft;
protected int mRight;
protected int mTop;
protected int mBottom;
```

这些变量表示的是该View在4个方向上的位置与其父View的差值（以像素为单位）。比如mLeft指的是它的左边缘与父View左边缘的距离，如图11-14所示。

实际上，这4个值不仅固定了View的位置，同时也决定了View的大小。比如getWidth的内部实现如下：

```
    public final int getWidth() {
        return mRight - mLeft;
    }
```

在整棵View Tree的遍历过程中，系统会综合考虑所有View对象的需求，然后为这些成员变量赋值，所以并不建议外部程序直接通过接口来设置它们；而且即便我们通过外部手段改变了这些变量，它们在下一次layout时很可能还会被系统还原回来。

2．Size

View.java中与此相关的内部变量包括：

```
private int mMinWidth;
private int mMinHeight;
int mMeasuredWidth;
int mMeasuredHeight;
```

前两个变量表示这个View对象所希望的最小宽、高值，可以通过android:minWidth和android:minHeight来配置。我们在前面讲解View Tree遍历的小节看到过，系统将尽量保证使用者的这个需求。

后两者是measure(int,int)后的计算结果，并不代表View的真正宽高。

3．Padding

Padding是View内部四周的填空空间，或者更确切地说，是它的“内容区域”与外边框的距离，如图11-15所示。

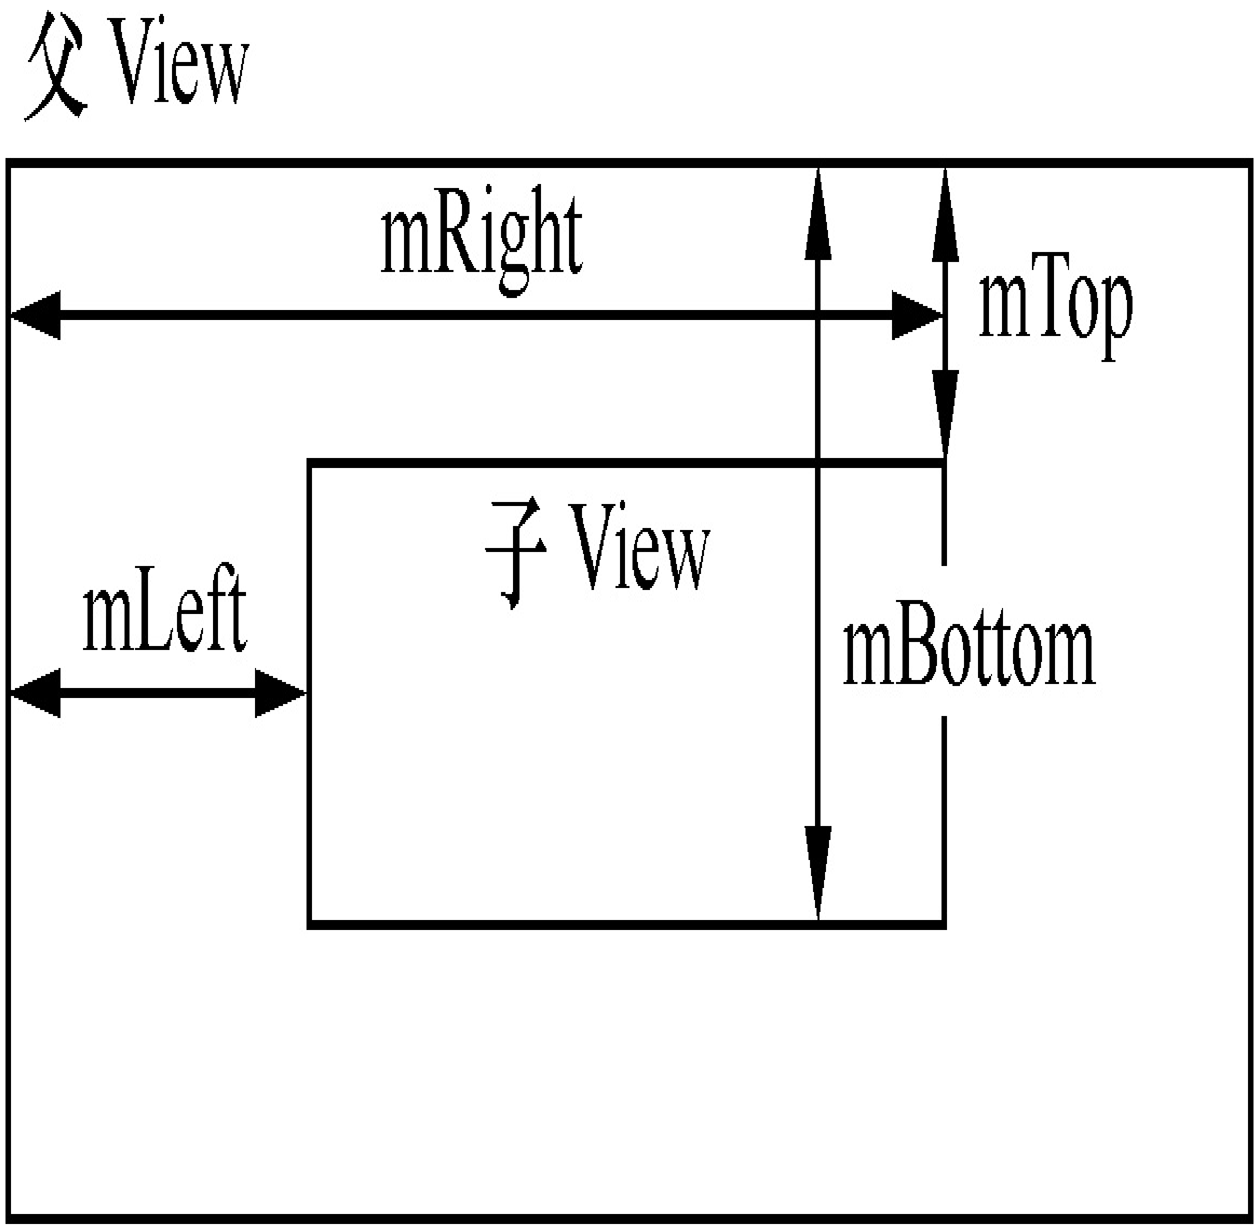

▲图11-14　View在4个方向上的位置与其父View的差值

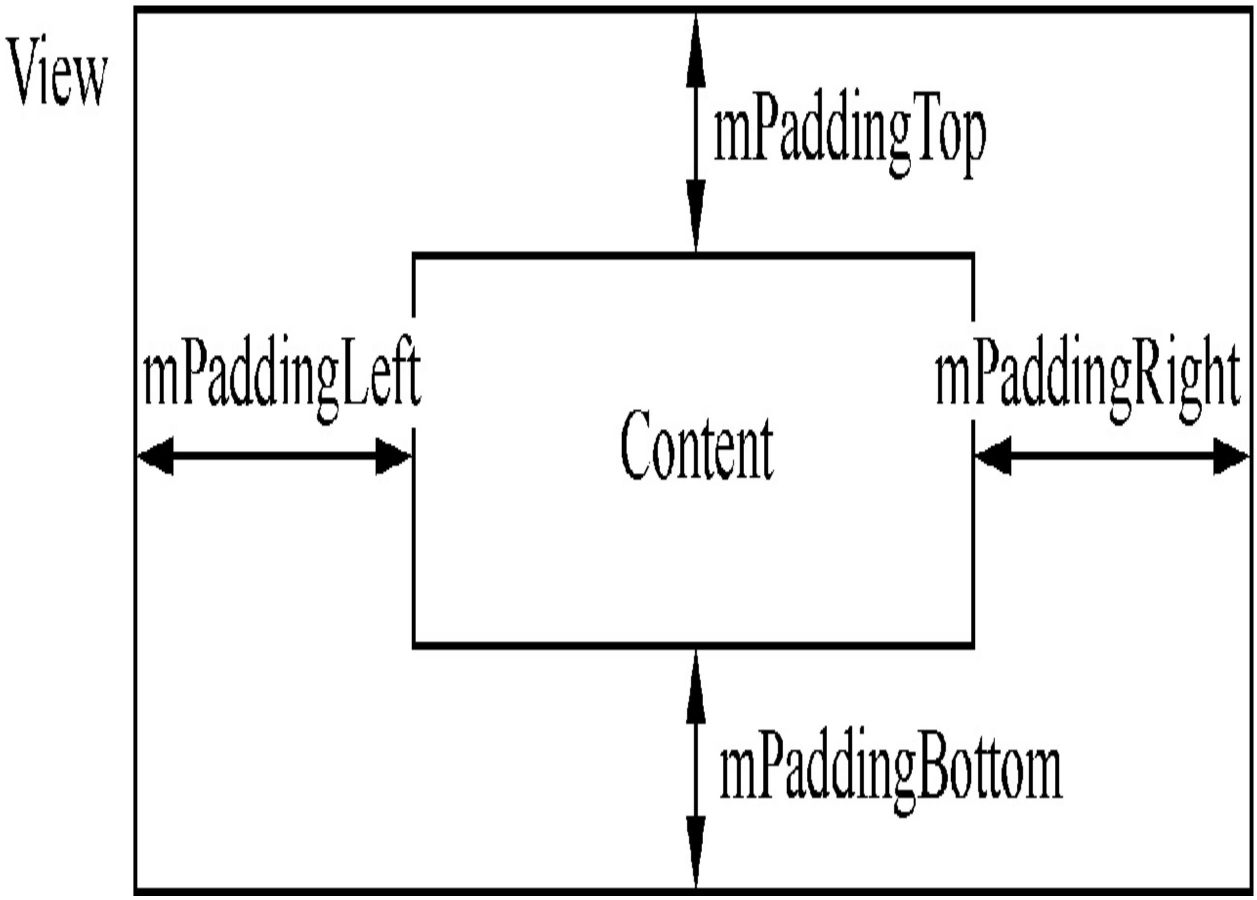

▲图11-15 “内容区域”与外边框的距离

View.java中与此相关的内部变量包括：

```
protected int mPaddingLeft;
protected int mPaddingRight;
protected int mPaddingTop;
protected int mPaddingBottom;
protected int mUserPaddingLeft;
protected int mUserPaddingRight;等
```

Padding值需要考虑以下几个因素。

- 用户设置的padding

应用开发者可以通过android:padding、android:paddingLeft、android:paddingRight、android: paddingTop、android:paddingBottom等属性值来指定填充边距的大小。当View对象构造时，系统会优先考虑这一设置。

- 其他

如果用户没有显式指定padding值，系统将使用默认的padding值（或者从background drawable中获取的padding）。

4．Gravity

我们已经比较了gravity和layout_gravity的区别，前者表达了View内部Content的重心位置，而后者则是View在ViewGroup中的重心位置。

实际上gravity并不是View基类的属性。换句话说，View类中没有处理这个属性。这也是合情合理的，因为View本身并没有实现onDraw方法，所以继承View的各子类必须根据自己的需求来“画”出想要的“内容”以及“内容”的位置。比如在TextView组件中：

```
TextView(…){
     case com.android.internal.R.styleable.TextView_gravity:
                setGravity(a.getInt(attr, -1)); //记录用户在xml中提
                break;
     …
```

这段代码中的setGravity会把这一属性值存储到TextView类的成员变量mGravity中：

```
private int mGravity = Gravity.TOP | Gravity.START;
```

这里有必要了解下Gravity这个类，它是专门用于表示“gravity”属性相关值的一个类，例如：

```
int TOP = (AXIS_PULL_BEFORE|AXIS_SPECIFIED)<<AXIS_Y_SHIFT;
int LEFT = (AXIS_PULL_BEFORE|AXIS_SPECIFIED)<<AXIS_X_SHIFT;
```

其中AXIS_X_SHIFT和AXIS_Y_SHIFT分别是0和4，即前4位用于表示x轴的重心位置，后面几位则是y轴重心位置。4个bit位分别表示如表11-5所示。

表11-5　4个bit位的含义

Bit	bit3	bit2	bit1	bit0

Name	clip	pull_after	pull_before	specified
Description	边缘是否要根据container大小进行裁剪	被“拉”到right/bottom边缘的位置	被“拉”到left/top边缘的位置	这个轴是否已经设置过

比如Gravity.TOP指的是y轴上对top边缘的操作，即：

```
(AXIS_PULL_BEFORE|AXIS_SPECIFIED)<<AXIS_Y_SHIFT
```

而Gravity.LEFT则是x轴上对left边缘的操作，具体如下所示。

```
(AXIS_PULL_BEFORE|AXIS_SPECIFIED)<<AXIS_X_SHIFT
```

之所以叫pull，是因为边缘线是被“拉”到某个位置上的。换句话说，如果同时“拉”两个方向上的边缘线，则Object的大小也会变大。比如：

```
Gravity. FILL_VERTICAL = TOP|BOTTOM;
```

5．Visibility

可见性也是在开发中常见的一种属性。它有3种值可选，具体如下所示。

- VISIBLE：当前的View处于可见状态，因而它会被“画”出来。
- INVISIBLE：当前的View处于不可见状态。
- GONE：在INVISIBLE的情况下，虽然View的内容是不可见的，但是它所占据的空间位置却是不变的。而GONE则相当于完全移除View这个对象，系统不再为它保留空间位置。

6．Scrollbar

滚动条本身只是表达当前显示内容在整体内容中位置的一个组件，

如TextView在显示较多文字时就需要有类似指示。它让用户产生一种错觉，好像我们的View尺寸足以容纳整篇文章，只不过屏幕不够大而已（但实际上View的尺寸并没有想象中那么大）。

Scrollbar在View内部以ScrollabilityCache类型的mScrollCache变量统一管理，如表11-6所示。

表11-6　ScrollabilityCache类型的mScrollCache变量

Related Member	Description
ScrollabilityCache.OFF，ScrollabilityCache.ON	Scrollbar是否存在
ScrollabilityCache.scrollBarSize	Scrollbar大小
View.mVerticalScrollbarPosition	Scrollbar当前滚动位置
通过View.viewFlagValues |= scrollbarStyle & SCROLLBARS_STYLE_MASK来记录	Scrollbar的样式
ScrollabilityCache .scrollBar	Scrollbar背景图片

要特别注意Scrollbar与mScrollX/mScrollY的区别和联系。简单来讲，Scrollbar是内容（比如文本）的滚动条，而后两者则是View视图的滚动位置。Scrollbar是用于提示用户当前内容位置的，它对View本身的显示内容并不产生影响，而mScrollX/mScrollY则真正体现了View的这些属性。或者可以这样理解：Scrollbar是给用户看的，想象一下在没有屏幕的情况下，它将一无是处；而另外两者是基于“内存”的操

作。

实例如图11-6和图11-7所示。

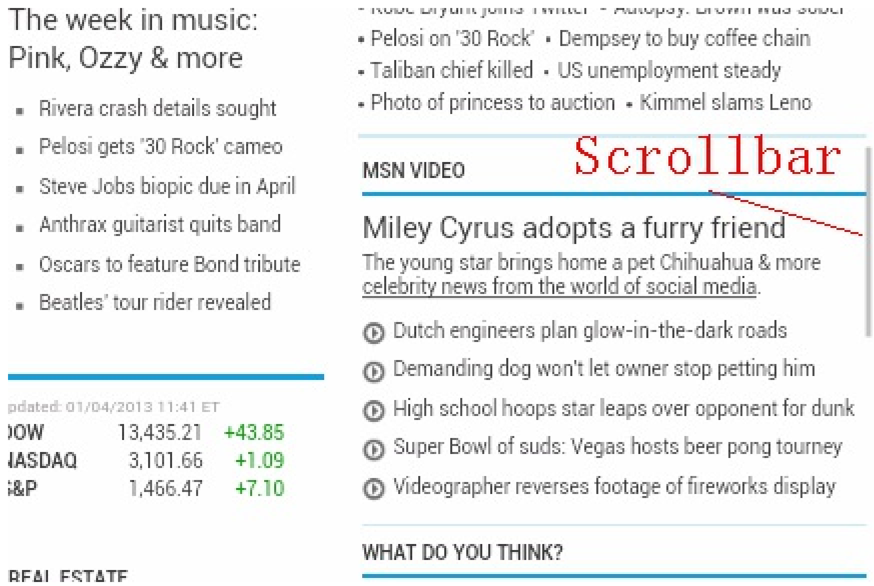

▲图11-16　Scrollbar实例

▲图11-17　mScrollX实例

图例显示了Scrollbar和mScrollX的区别。图11-16中，Scrollbar表示用户当前阅读到的内容在整版中的位置；图11-17则是我们常见的桌面Launcher，它由一个ViewGroup添加了若干个子View组成，每个桌面页都是一个View对象。当拖动屏幕时，改变的就是mScrollX的值——也就是屏幕上显示的这一部分界面，距离整个ViewGroup左边界的位移。当然，因为ViewGroup同时也是个View，如果把Launcher加上一个Scrollbar也完全是可以的，这时的“内容”就指的是其中容纳的若干个View了。

11.7.2　ViewGroup的属性

ViewGroup继承自View，因而它具有View的所有属性。另外，ViewGroup还有其自己的特性，我们统一列在表11-7中。

表11-7　ViewGroup的UI属性

<table>
<tr><th>UI属性</th><th colspan="2">相关方法与布局属性</th><th>描　　述</th></tr>
<tr><td rowspan="2">Margin</td><td>相关方法</td><td>setMargins (int left, int top, int right, int bottom)</td><td rowspan="2">ViewGroup.MarginLayoutParams是从ViewGroup中独立出来专门处理margin的类</td></tr>
<tr><td>布局属性</td><td>android:layout_marginLeft
android:layout_marginTop
android:layout_marginRight
android:layout_marginBottom</td></tr>
<tr><td rowspan="2">Layout</td><td>相关方法</td><td></td><td rowspan="2">ViewGroup.LayoutParams是从ViewGroup中独立出来专门处理Layout的，与之对应的是layout_heigh和layout_width两个布局属性——这两者的使用非常广泛，几乎所有应用程序都需要配置它们。
在前一小节描述View属性的表格中我们讲解过，它们在View对象中配置，却在ViewGroup中处理。有3种取值：
FILL_PARENT：废弃值，不建议使用
MATCH_PARENT：和父对象一样大
WRAP_CONTENT：只需要能刚好覆盖内容（包括padding）所占的空间大小即可</td></tr>
<tr><td>布局属性</td><td>android:layout_height
android:layout_width</td></tr>
</table>

11.7.3　View、ViewGroup和ViewParent

这三者既有联系又有区别，如图11-18所示。

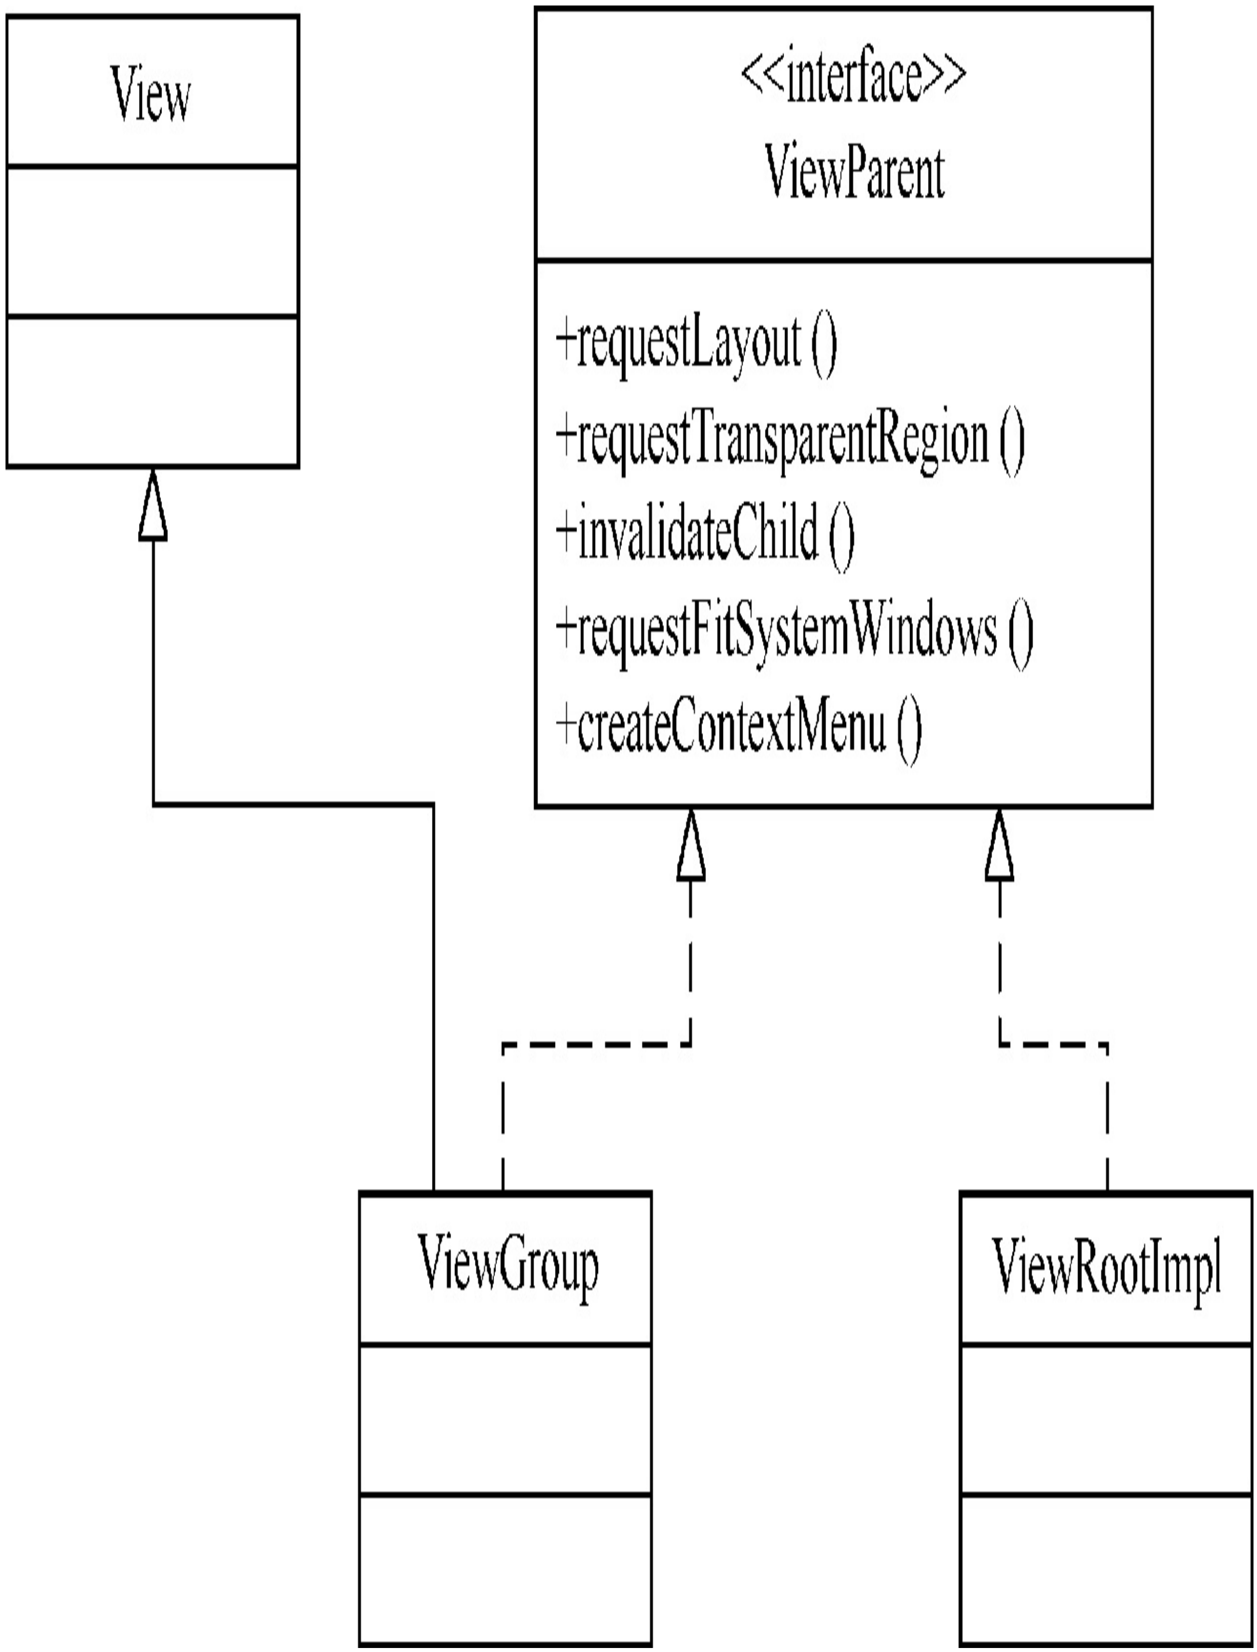

▲图11-18 View、ViewGroup和ViewParent

View确切地说是一个抽象的视图对象（虽然这个类不是抽象的），它定义了一个视图所需具有的属性和基本操作方法。ViewGroup本质上也是一个View，我们可以理解为ViewGroup中的Content是由若干个View组成的。ViewParent顾名思义是一个View的“父亲”。这个父亲既可能是ViewGroup，也可能是ViewRoot。也就是说，对于View Tree的“根”（通常它是一个ViewGroup），它的“父亲”是ViewRoot；而其他元素的“父亲”则是ViewGroup。

11.7.4 Callback接口

```
public class View implements Drawable.Callback, KeyEvent.Callback
       AccessibilityEventSource {       ….
```

由以上代码可知View类实现了以下几个接口，如图11-19所示。

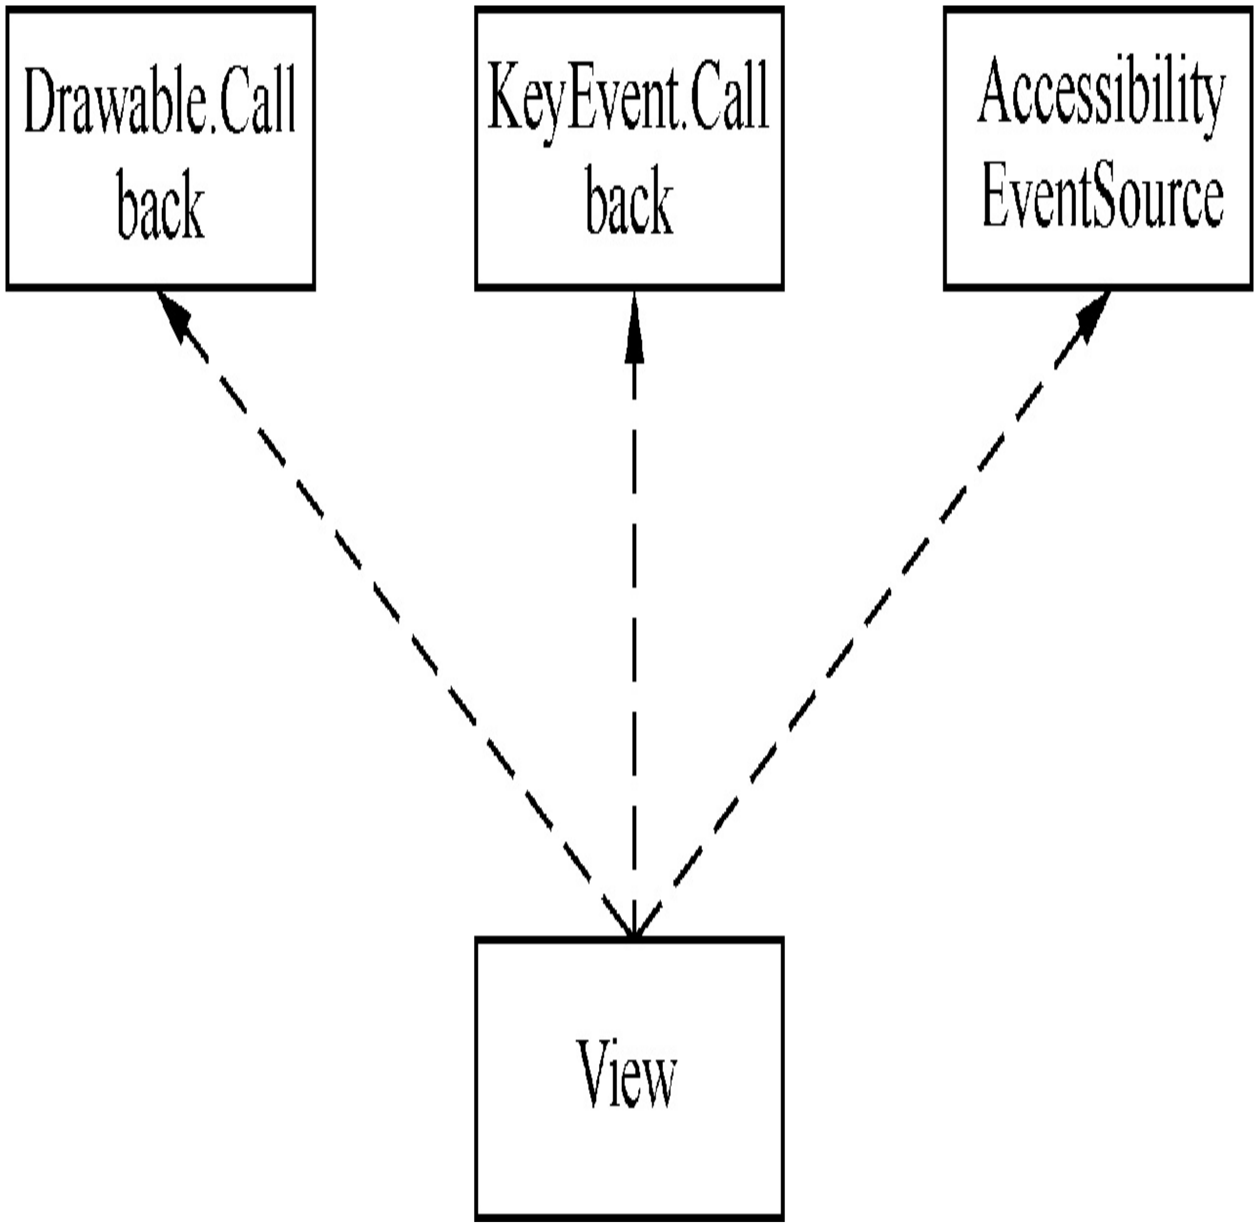

▲图11-19 View类实现的回调接口

从中可以得到以下几点信息：

- View类中将会使用Drawable；
- View会监听KeyEvent；
- View中使用了AccessibilityEvent。

AccessibilityEvent是系统发送的，反映UI变化的事件。比如按钮点击、某个View获得了焦点等。

先来看看什么是Drawable，这不仅是Android显示系统中的一个重要概念，也是应用开发人员在实现UI交互界面时经常会接触到的。

按照Android的解释，Drawable就是“Something that can be drawn”的抽象。也就是说，它表达了我们希望在屏幕上绘制的图像。举个例子，一个Bitmap文件就可以说是Drawable，因为它承载了图片的数据。这些数据不依赖于设备平台，只是图片自身内容的反映（想象一下一张小狗的Bitmap图片，它不管在Android设备上，还是在Windows操作系统上，显示出来都是一样的，不会变成其他动物）。

读者可能会觉得奇怪，我们的View类不也有数据储存这个功能吗，它与Drawable有什么区别呢？

区别就在于View不仅仅包含了图片数据，还需要处理各种事件（比如触摸事件、按键事件等）。我们可以用图11-20来概括它们之间的关系。

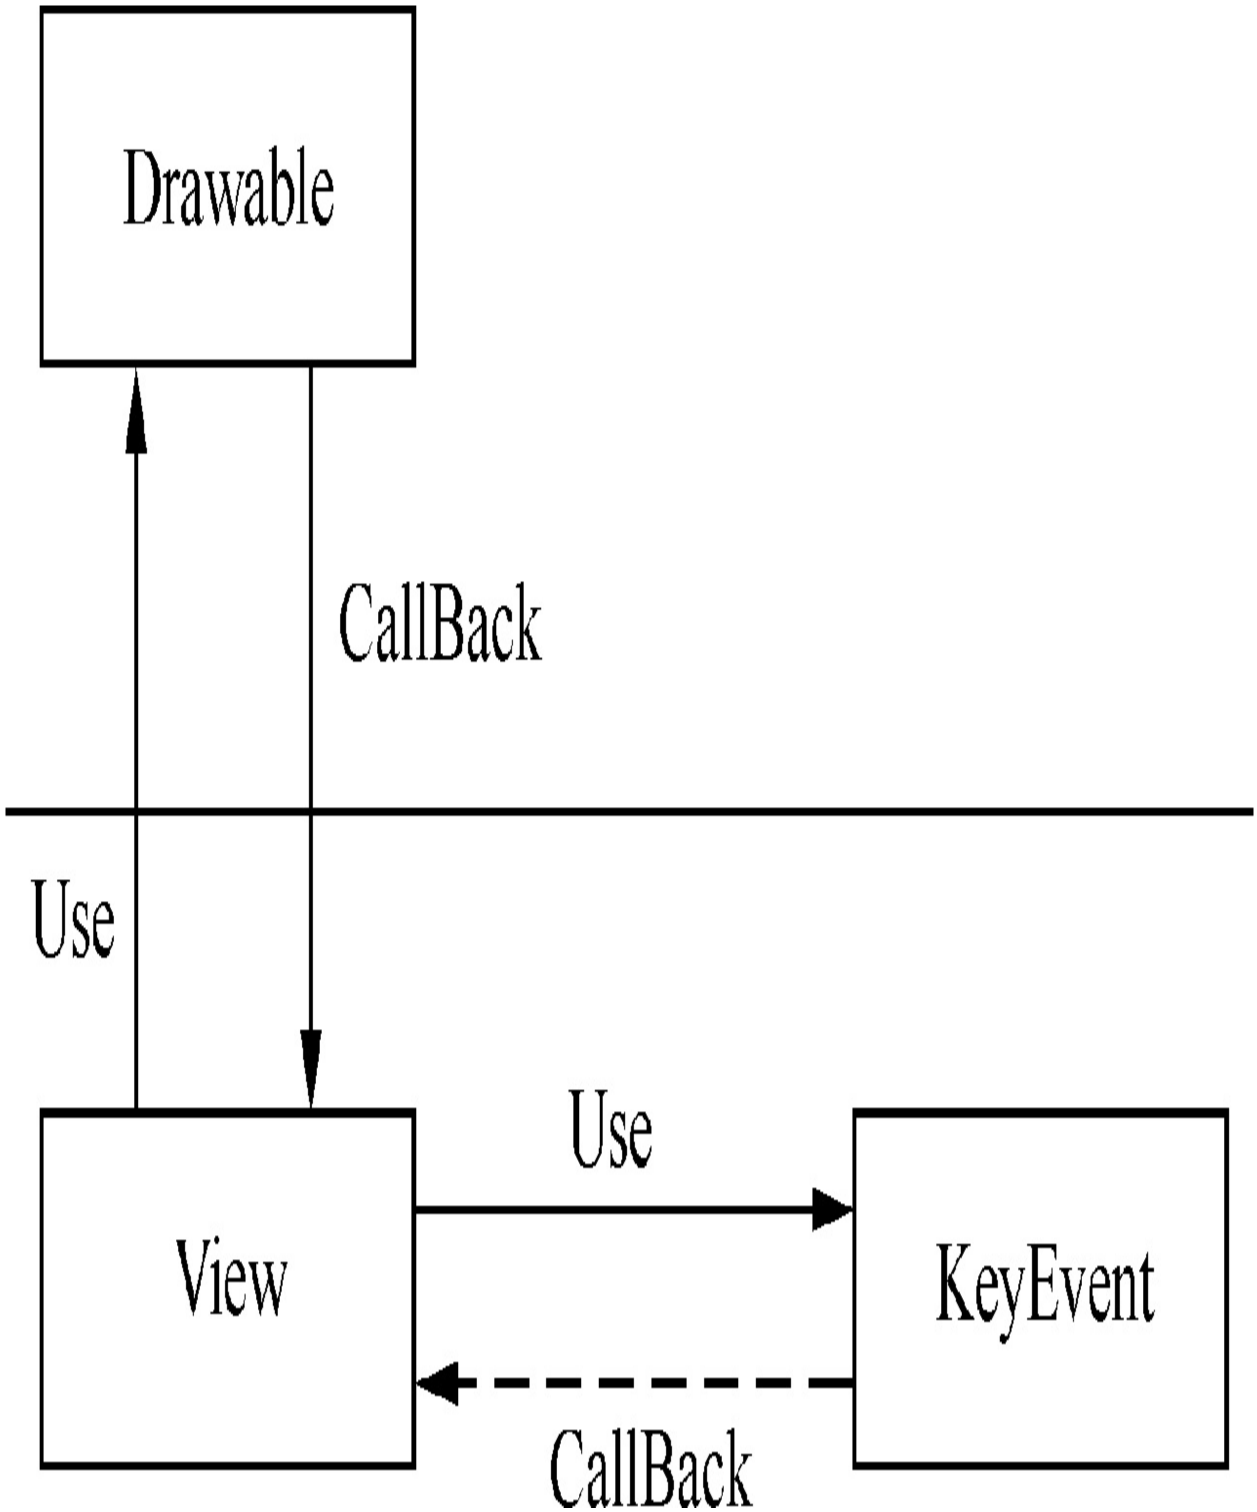

▲图11-20 View与Drawable的关系图

Drawable通常会以如下形式出现。

- Bitmap

这是形式最简单的Drawable，除了图像本身，基本上不带任何附加信息，如一张PNG或者JPEG图。

- Nine Patch

Android系统自定义的一种格式，是PNG的扩展。它的初衷是使图片在伸缩时不至于严重变形，因而文件本身会附加关于拉伸操作的具体信息。

- Shape

它不仅包含了原始的图片数据，而且提供了简单的绘图命令来保证我们在某些图像尺寸变化的场合能产生比较好的效果。

- Layers

复合Drawable中的一种。Layer表示“层”，复数形式表示会有多个“层”，这些层不断地叠加在彼此之上。

- States

复合Drawable中的一种。State代表“状态”，因此States表示多种状态以及每种状态所对应的图像。这在应用开发中使用比较频繁，如一个按钮有over，pressed和normal等多种状态，显然我们在UI界面的设计上要体现出这些状态的不同——通常情况下，当按钮被按下时，会高显或加深颜色显示。Android的View机制提供了非常便利的方式来满足开发者的多状态显示需求：我们只要在一个相关的xml中定义按钮的若干种状态以及某种状态出现时对应的图片即可，剩下的难题系统会自动解决。

- Levels

复合Drawable中的一种，和上面的States有点类似。区别在于它是以Level值来决定需要采用哪种图片的，而不是State。比如信号格数分为0～5六个Level，那么在具体情况下就可以显示对应的图片。

- Scale

复合compound中的一种。从名字可以看出，它运用于需要调整尺寸大小的场合，即根据level值来决定图形的尺寸。

Drawable除了必不可少的图形数据外，还封装了不少操作函数。其主要分为创建、销毁、简单的图形处理、绘制等类别，有兴趣的读者可以参考官方文档。

既然Drawable只是图像数据的抽象，那么当图形有变化或者需要重绘时，就必然要通知View。完成这一操作的就是Drawable的Callback接口：

```
 public static interface Callback {
       /*当drawable需要被重绘时调用*/
       public void invalidateDrawable(Drawable who);
           /*用于drawable规划动画的下一帧*/
       public void scheduleDrawable(Drawable who, Runnable wh
          /*用于取消scheduleDrawable的操作*/
       public void unscheduleDrawable(Drawable who, Runnable 
}
```

下面是View类对invalidateDrawable方法的实现，其他两个函数不影响我们下一步的分析，因此暂时略过：

```
public void invalidateDrawable(Drawable drawable) {
    if (verifyDrawable(drawable)) {
        final Rect dirty = drawable.getBounds();/*获取drawable
             /*获取View的ScrollX与ScrollY*/
        final int scrollX = mScrollX;
        final int scrollY = mScrollY;
        invalidate(dirty.left + scrollX, dirty.top + scrollY,
                  dirty.bottom + scrollY);/*调用View内部的inval
                                 一个长方形的4条边，分别为left、to
    }
}
```

可见真正起绘制作用的是View中的invalidate函数（做过MFC开发的读者应该对这个函数不陌生，它是我们刷新屏幕上的图形时所需要调用的）。

这个invalidate函数在View类中有4个原型，如下：

```
public void invalidate(Rect dirty);
public void invalidate(int l, int t, int r, int b);
public void invalidate();
void invalidate(boolean invalidateCache);
```

关于invalidate的源码实现，在“View Tree的遍历时机”小节已经讲解过，这里不再赘述。

至此，我们已经将View类所实现的接口介绍完了。但还有一些问题并没有得到解决，如View是如何与Drawable联系起来的，又是如何最终将图形显示到屏幕上的。要理清这些问题，接下来还需要花点时间来学习几个重要的概念。

11.8 “作画“工具集——Canvas

Canvas的字面意思是“画布”，按照Android系统的解释，“The Canvas class holds the draw calls”。也就是说，它其实是将“图像”数据写入Bimap中的一个工具集，取名Canvas并不是非常贴切，容易引起误解。

大家可以想象下，如果需要在屏幕上“作画”，需要哪些支持（我们可以与画家的创作做类比）呢？

- Bitmap

这是存储数据的地方，类比于画家所用的纸张。在不同的系统实现中可能还会有进一步的封装，如我们之前谈到的Drawable以及它的众多子类。

- Canvas

作画的工具集，即辅助画家完成作品的一个“工具箱”。

- Drawing Primitive

Primitive一般用来形容那些不可再分割的元素。比如一个操作是由A、B两部分组成，而且这两部分是不可分割的，那么它们就组成了一个Primitive操作。在这里，Drawing Primitive就是指Rect，Path，Text等这些基础元素。

- Paint

如同画家在绘制不同风格的作品时，会用到各种画笔、着色手法、样式，我们在电脑上“作图”也是可以选择各式各样的Paint的。读者对Paint和Canvas的功能可能还是有点模糊。打个比方，Canvas就像一台打印机，它按照Primitive的描述来打出线条、长方形等；而Paint则是墨盒——这也就意味着，装上了不同颜色墨盒的同一台打印机，可以打印出色彩各异的线条、长方形，如图11-21所示。

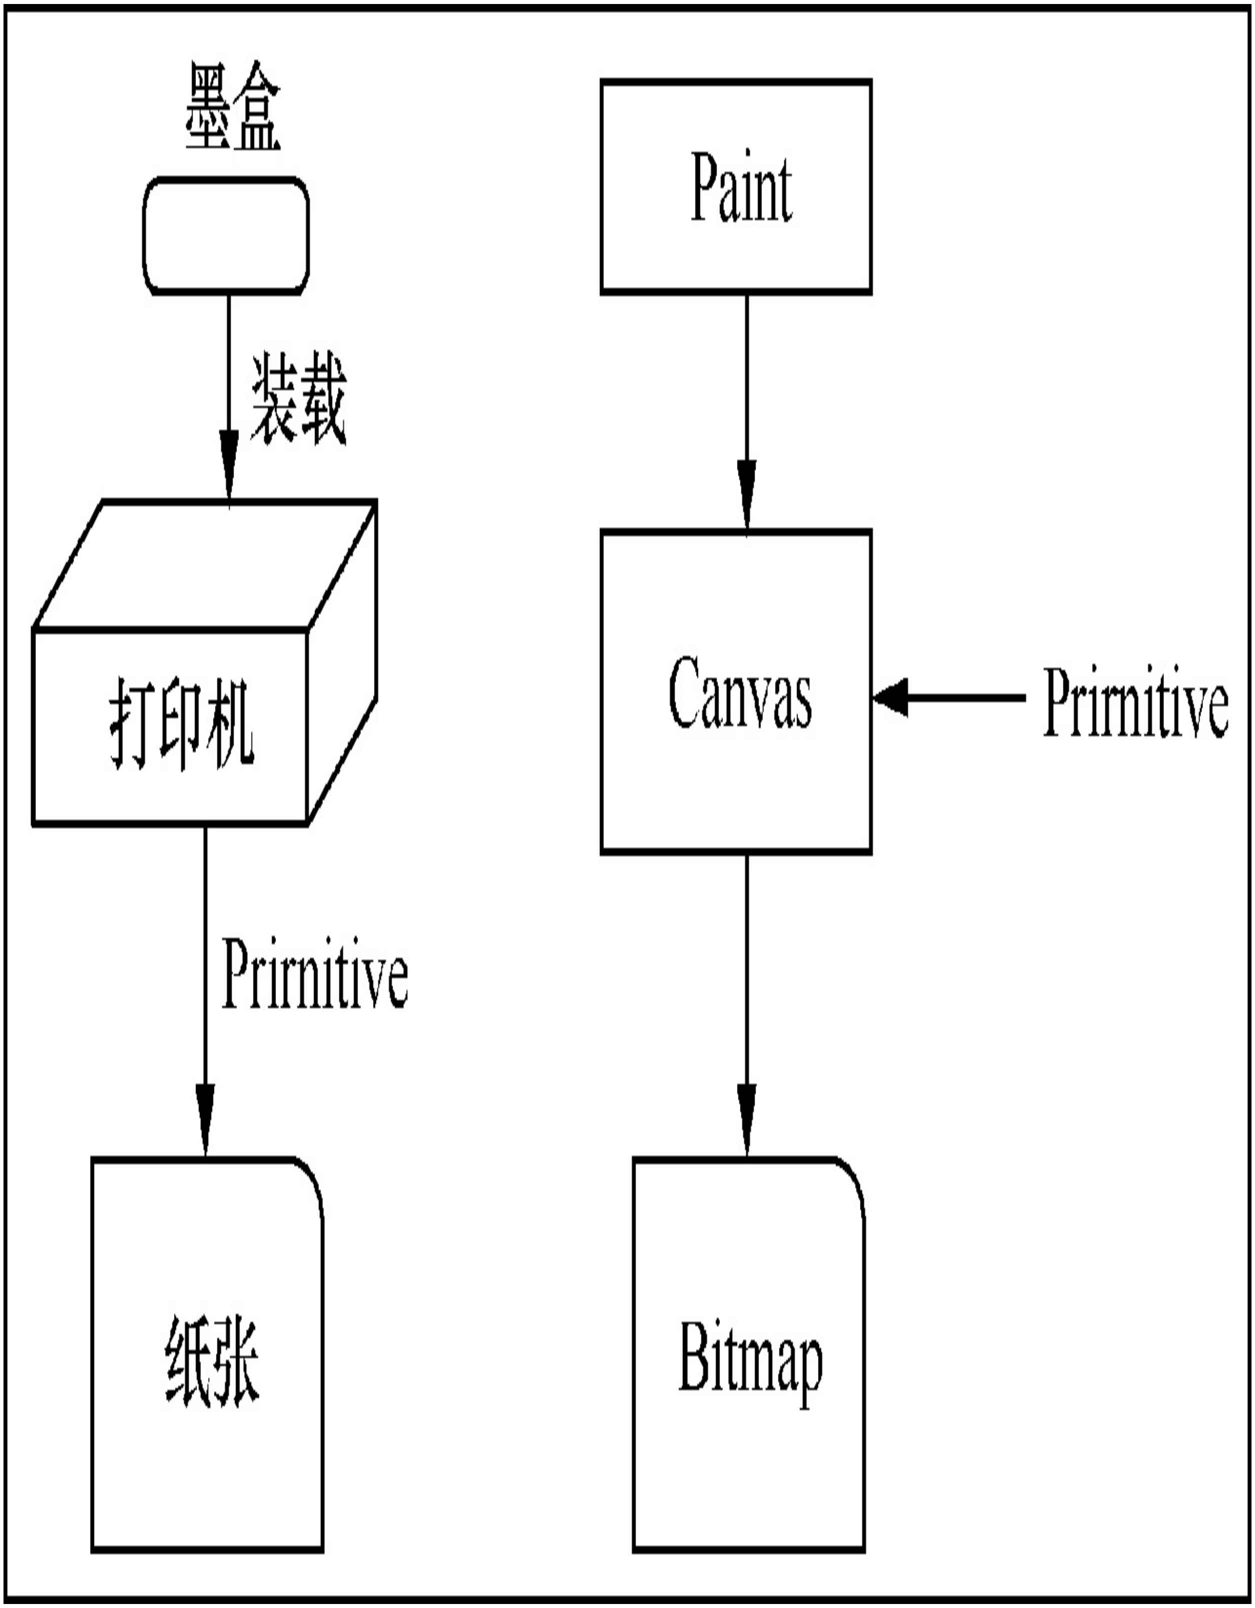

▲图11-21 Canvas类比手打印过程

我们知道，打印机的工作流程大致是：

（1）找到一台能正常工作的打印机（Canvas）；

（2）准备好需要的墨盒（Paint）；

（3）将墨盒装入打印机；

（4）准备好需要的纸张（Bitmap）；

（5）将纸张放入打印机的纸槽；

（6）通过某种传输途径（网络连接、U盘连接）向打印机（Canvas）发送打印命令，如画一条线、一个长方形或者文字等；

（7）打印机（Canvas）将结果输出到纸张（Bitmap）上；

（8）完成打印后，用户到打印机的纸张出口处获取已经打印好的纸张；

（9）用户检查纸张上的绘图结果是否符合预期要求。

这样读者对Canvas应该有一些初步的认识了。还有一点需要特别指出的是，Canvas这台“打印机”本身其实是带有“纸张”的——它内部封装了存储UI数据的内存空间。

接下来我们将分几个小节来逐步剖析Canvas。

11.8.1 “绘制UI”——Skia

实际上在应用程序中“绘制UI”的方法有很多种，并不拘泥于OpenGL ES。比如我们在SurfaceFlinger章节曾提到过的Skia，也是一个可行的方式。

如图11-22所示。

Skia是到目前为止Android仍然在采用的，适用于Java层View Tree中绘制UI界面的一个2D图形引擎库。本地层的Canvas和Bitmap实现，也都基于Skia。因而，我们有必要先对它做一个了解。

Skia最初由Skia Inc公司开发，并在2005年被Google收购。从这个时间点来看，我们有理由相信Google当时收购Skia的重要目的之一，就是给Android系统做准备。目前，Skia已经被应用到了除Android外的很多知名项目中，如Mozilla Firefox，Google Chrome，Chrome OS等。其源码项目的管理主页地址是：

http://code.google.com/p/skia/。

再来思考一下，市面上的开源图形库，特别是2D引擎的可选择性还是比较多的，为什么Google要大费周折地另起炉灶呢？换句话说，Skia的优势何在？

Skia公司的创始人是图形领域的顶级专家，George Michael（“Mike”）Reed博士。他曾在牛津大学任教近二十年（1986～2005年），不过从目前Oxford的Fellow List介绍（http://www.seh.ox.ac.uk/fellows-and-staff/emeritus-fellows)来看，很可能已经退休了。从2005年开始，他成为澳门UNU/IIST的Director（应该也已退任）。

Skia一开始就受到了外界的关注。其第一个产品SGL因在低配置的手持设备上表现出的高效性而被人称道。综合源码和一些文档说明，我们总结出Skia的优秀特性如下：

- 跨平台;
- 高度优化的渲染器;
- 可选的硬件加速（比如基于OpenGL）；
- 动画实现（源码目录external\skia\src\animator）；
- 图片解码（JPG\PNG\GIF\BMP等，源码目录external\skia\src\images）；
- 文本绘制能力（源码目录external\skia\src\text）；
- 支持多种特效（源码目录external\skia\src\effects）。

……

了解了Skia的基础知识后，我们再回到Canvas的分析中，并以此为契机进一步挖掘关于Skia的更多知识。

11.8.2 数据中介——Surface.lockCanvas

大家要知道，与View组件直接打交道的是Canvas，而不是Drawable。比如View类中的绘图函数：

```
draw(Canvas canvas);
```

其参数中传入的就是一个可用的Canvas。

不过根据前一章节的学习，我们又了解到应用进程端与SurfaceFlinger间的数据中介并不是Canvas，而是Surface。这就不可避免地存在一个问题，即Canvas和Surface之间是如何协作的。

ViewRootImpl中取得一个Canvas的方法如下：

```
canvas = mSurface.lockCanvas(dirty);
```

lockCanvas是一个jni函数，对应的实现核心如下：

```
/*frameworks/base/core/jni/android_view_Surface.cpp*/
static void nativeLockCanvas(JNIEnv* env, jclass clazz,
        jint nativeObject, jobject canvasObj, jobject dirtyRectOb
    sp<Surface>surface(reinterpret_cast<Surface *>(nativeObject))
    …
    //计算dirty region,代码略…
    ANativeWindow_Buffer outBuffer;//用于存储UI数据的Buffer
    Rect dirtyBounds(dirtyRegion.getBounds());
    status_t err = surface->lock(&outBuffer, &dirtyBounds);//获取-
    …
    SkBitmap bitmap;
    ssize_t bpr = outBuffer.stride * bytesPerPixel(outBuffer.form
    bitmap.setConfig(convertPixelFormat(outBuffer.format), outBuf

    …
    if (outBuffer.width > 0 && outBuffer.height > 0) {
        bitmap.setPixels(outBuffer.bits);//为Bitmap分配可用的数据空间
    } else {
        bitmap.setPixels(NULL);
    }
    SkCanvas* nativeCanvas = SkNEW_ARGS(SkCanvas, (bitmap));//通过
swapCanvasPtr(env, canvasObj, nativeCanvas);/*将本地Canvas保存到Jav
                                                            对象的成员
    …
}
```

我们最关心的问题是，Canvas中自带的“纸张”从何而来？可以肯定的是，它与Surface有关系，所以我们沿着这条线索来分析源码。注意区别源码中有两个Surface，分别面向Java层（对应函数参数clazz）和C++本地层（对应参数nativeObject）。函数首先通过强制类型转换来把nativeObject变成本地的Surface对象。

本地Surface对象随后通过lock（&info，&dirtyRegion）来获取一个可用的Buffer。这个ANativeWindow_Buffer大有文章，其内的bits就是我们要找的“纸张”：

```
typedef struct ANativeWindow_Buffer {
    int32_t width;//宽度，以像素为单位
```

```
    int32_t height;//高度，以像素为单位
    int32_t stride;//内存中buffer的每一行所占的像素值，可能大于等于width
    int32_t format;//缓冲区格式，即WINDOW_FORMAT_*
    void* bits;//存储数据的地方
    uint32_t reserved[6];//保留
} ANativeWindow_Buffer;
```

所以问题进一步转化为：bits如何在接下来的步骤中“封存”到Canvas中？

Java层的Canvas与Surface在本地都有与之相对应的类，分别是SkCanvas和Surface，后两者由C++编写。本地的Canvas在上面函数中的变量名为nativeCanvas，由如下语句构造完成：

```
SkNEW_ARGS(SkCanvas, (bitmap));
```

这个宏定义展开来就是new SkCanvas(bitmap)，即生成了一个SkCanvas对象，且以bitmap作为构造函数的入参。

因为Canvas/SkCanvas只是“打印机”，其内部的“纸盒”需要装载“打印纸”才能正常工作，这就是SkBitmap——从名称上可以看出，它和SkCanvas都属于Skia工程。

程序使用了bitmap变量来表示一个SkBitmap，不过一开始它只是一个“空壳”，真正存储图形数据的内存块还需要通过setPixels来配置。所以前面ANativeWindow_Buffer内部的ANativeWindow_Buffer.bits所指向的内存地址被作为参数传入SkBitmap中。这样SkBitmap才是一个有效的类。

经过这些操作后，SkCanvas就成功地装载了“打印纸”。当然，最终lockCanvas函数返回的还是Java层的Canvas对象，这是由JNI机制所决定的。

Surface，Canvas等元素的关系如图11-23所示。

明白了整体流程后，我们再来详细分析Surface.lock获得的内存块（bits）的由来。

根据前面章节的分析可知，Surface(C++)是OpenGL ES的本地窗口之一。不过，这并不代表它必须要借助于OpenGL ES来完成UI绘制。事

实上，Surface具有两面性甚至多面性。或者用更通俗的话讲，它的职责只是管理SurfaceFlinger分配的用于存储UI数据的“内存块”而已。至于上层有多少种不同用户以及由此所产生的各种对Surface的使用方法，它是不需要理会的。如图11-24所示。

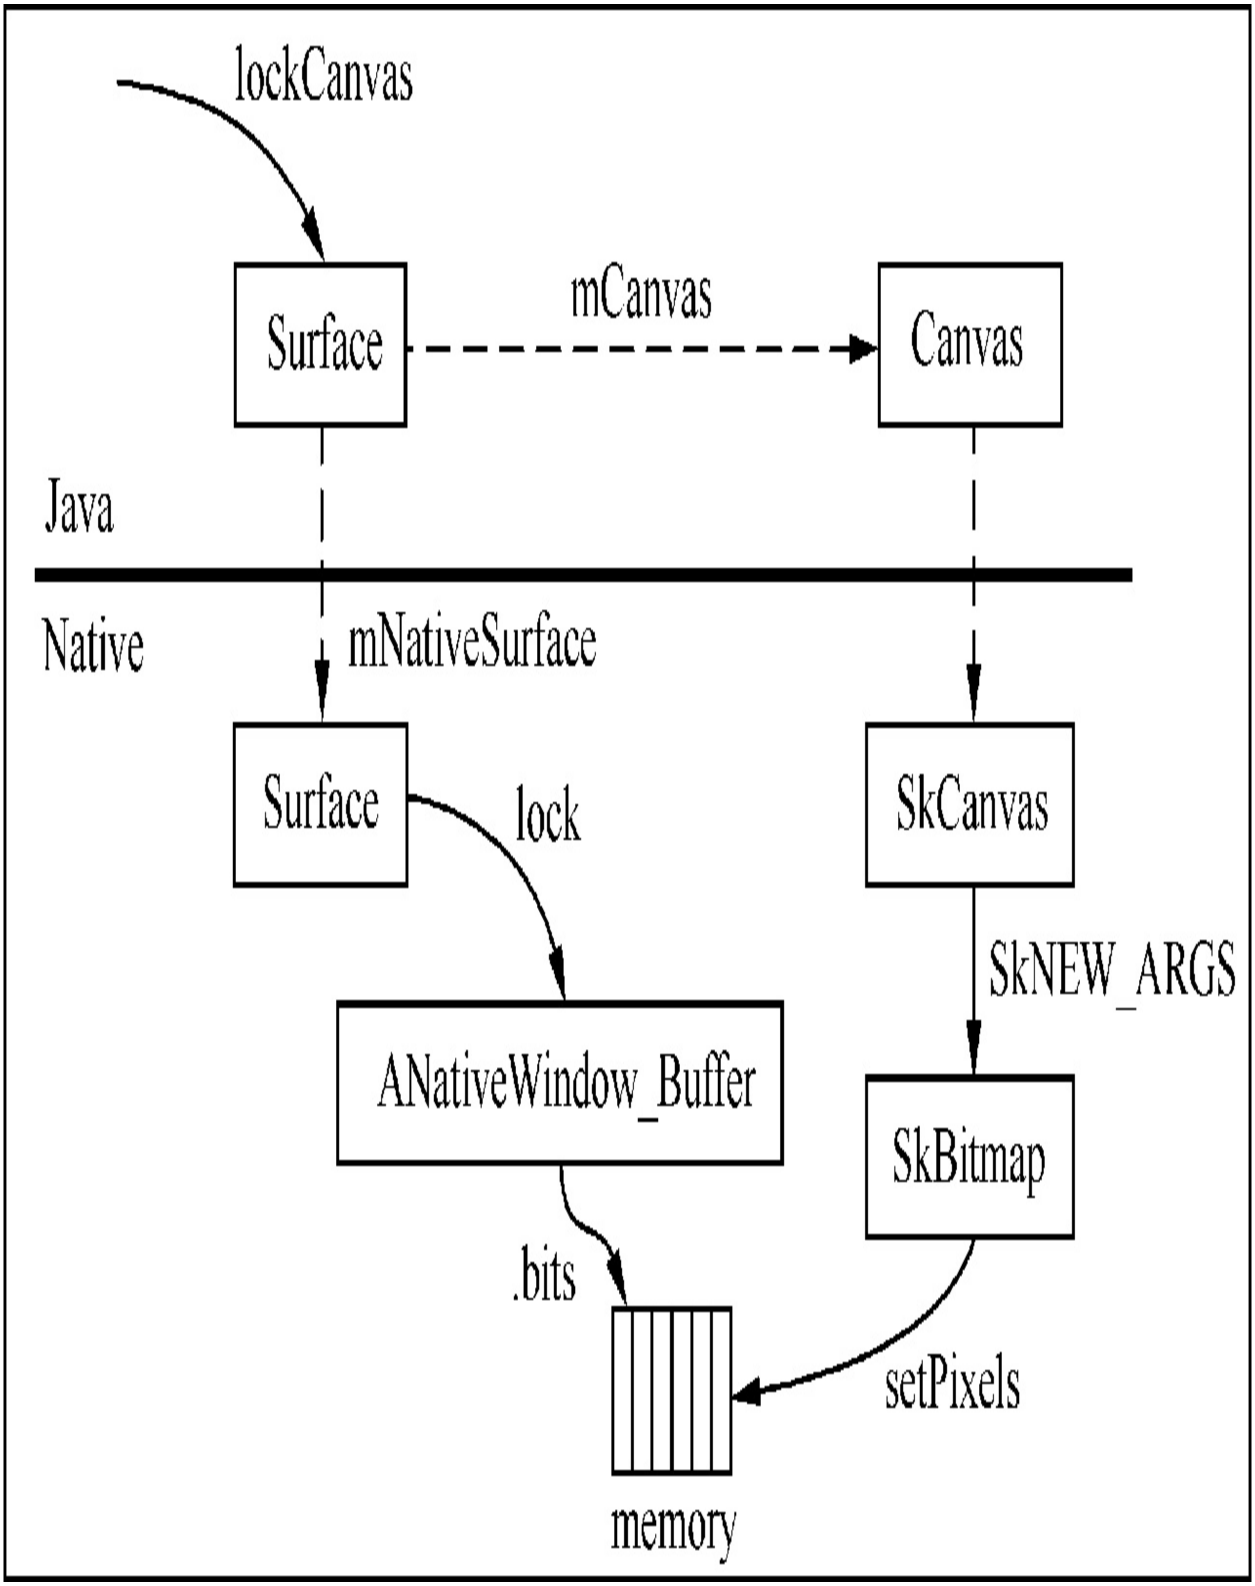

▲图11-23　lockCanvas各元素关系图

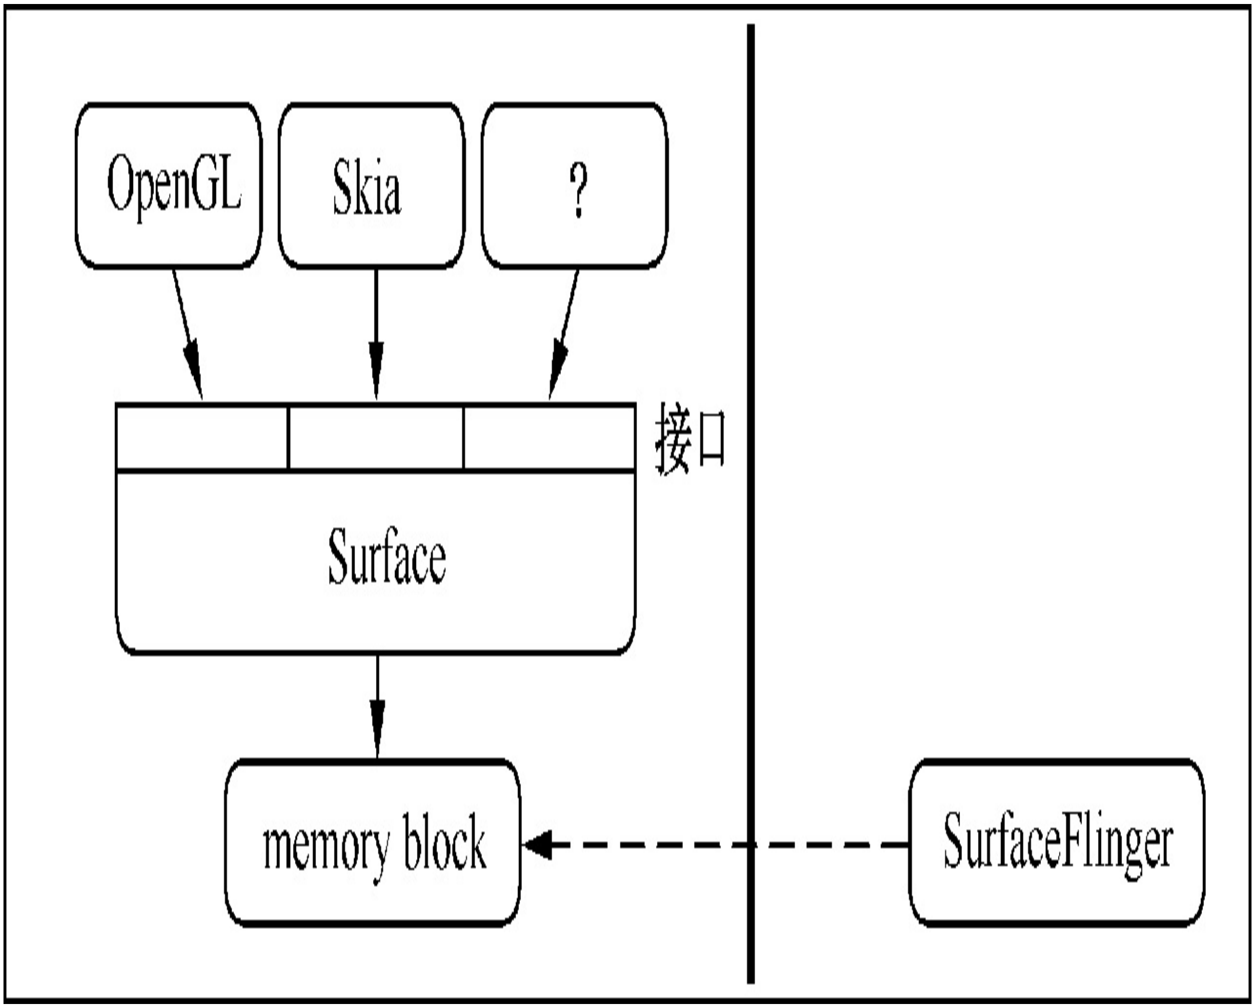

▲图11-24　Surface的多面性

因此Surface只是一个中介而已，它将通过与SurfaceFlinger的一系列协作来满足上层的需求。比如lock的实现如下：

```
/*frameworks/native/libs/gui/Surface.cpp*/
status_t Surface::lock( ANativeWindow_Buffer* outBuffer, ARect* i
{
    if (mLockedBuffer != 0) {//Step1. 判断当前是否已经有buffer被locke
        ALOGE("Surface::lock failed, already locked");
        return INVALID_OPERATION;
    }

    if (!mConnectedToCpu) {//Step2. 当前是否已经建立必要的连接
        int err = Surface::connect(NATIVE_WINDOW_API_CPU);/*Step3
        …
        /*Step4. 设置内存块的用法*/
        setUsage(GRALLOC_USAGE_SW_READ_OFTEN | GRALLOC_USAGE_SW_W
```

```
    }

    ANativeWindowBuffer* out;
    int fenceFd = -1;
    status_t err = dequeueBuffer(&out);/*Step5. 从buffer队列中deque
    if (err == NO_ERROR) {
        sp<GraphicBuffer> backBuffer(GraphicBuffer::getSelf(out))
        …
        /*Step6. backBuffer与frontBuffer*/
        const sp<GraphicBuffer>& frontBuffer(mPostedBuffer);//上一
        const bool canCopyBack = (frontBuffer != 0 &&backBuffer->
                    backBuffer->height == frontBuffer->height &&
                    backBuffer->format == frontBuffer->format);//
            if (canCopyBack) {
                /*计算可以从上一次的buffer中copy多少数据*/
                const Region copyback(mDirtyRegion.subtract(newDi
                if (!copyback.isEmpty())
                    copyBlt(backBuffer, frontBuffer, copyback);
            } else {
                /*如果无法利用上一次的计算结果，那么要告知上层用户，它们要
                //代码省略
            }
            …
            void* vaddr;
            /*Step7. 锁定buffer*/
            status_t res = backBuffer->lock(GRALLOC_USAGE_SW_READ
                        GRALLOC_USAGE_SW_WRITE_OFTEN,newDirtyReg
            if (res != 0) {
                err = INVALID_OPERATION;
            } else {/*Step8. 收尾工作，以及函数出参赋值*/
                mLockedBuffer = backBuffer;
                …
            }
        }
    }
    return err;
}
```

Step1@Surface::lock。当前被locked的buffer最多只能有一个，以mLockedBuffer来表示，这是一个GraphicBuffer类型的强指针变量。当每次lock成功后，它就会被赋值为当前被locked的buffer；而当UI绘图结束并调用unlockAndPost时，这个mLockedBuffer会被清空，且另一个变量mPostedBuffer用于记录最近一次的post操作。

因而在lock函数的最开始，我们要判断mLockedBuffer是否为空：

假如不是，就要避免再次锁定一个buffer。这种情况将直接返回INVALID_OPERATION类型的错误。

Step2@Surface::lock。接下来，程序还需要判断mConnectedToCpu是否为true。这个变量名称有点怪，实际上它想表达的意思是——在此之前是否已经成功地执行了IGraphicBufferProducer. connect。而名称最后的“cpu”是指connect的类型，包括表11-8所列的几种。

表11-8　connect的类型

类　型	描　述
NATIVE_WINDOW_API_EGL	当buffer被OpenGL ES填充完成后，将由EGL通过eglSwapBuffers来入队（queue）
NATIVE_WINDOW_API_CPU	当buffer被CPU（也就是软件计算）填充完成后，入队处理
NATIVE_WINDOW_API_MEDIA	当buffer被video decoder填充完成后，由Stagefright来执行入队
NATIVE_WINDOW_API_CAMERA	由camera HAL来调用入队操作

在当前这个场景中，显然连接类型选择的是NATIVE_WINDOW_API_CPU。

Step3@Surface::lock。假如mConnectedToCpu为false，则主动调

用connect函数来完成连接，从函数入参值也可以验证前面对类型的判断。

Step4@Surface::lock。紧接着我们设置内存块的用法，如buffer是否经常被软件读写。这个值并不会马上传递给SurfaceFlinger，而是先存储到内部的成员变量mReqUsage中，在后续的dequeueBuffer中才作为参数告知SurfaceFlinger。

Step5@Surface::lock。一切准备就绪，现在可以向SurfaceFlinger申请一个可用的buffer了。这一部分的源码实现在前几个章节已经详细分析过，这里就不再赘述。

Step6@Surface::lock。这段代码有两个重要变量，即backBuffer和frontBuffer。需要特别注意的是，它们并不是前面章节中提及的双缓冲区概念，而是分别代表当前正在处理的buffer和上一次处理的buffer。

两次图像更新间通常并不需要重新绘制整个屏幕区域，因而我们完全可以借助于之前buffer的计算结果来填充本次的buffer内容，以加快处理速度。判断两个buffer间能否复制的标准之一是canCopyBack，判断条件包括：frontBuffer!=0，并且两者的宽、高和格式必须完全一致。在这个变量为true的情况下，程序会计算出需要复制的那一部分区域大小，并由copyback来表示，最后通过copyBlt函数来完成复制过程。

假如前后两次buffer不能复制，那么我们要告知使用者必须刷新整个屏幕区域。为了帮大家加深印象，我们以对话形式来描述这一过程，如图11-25所示。

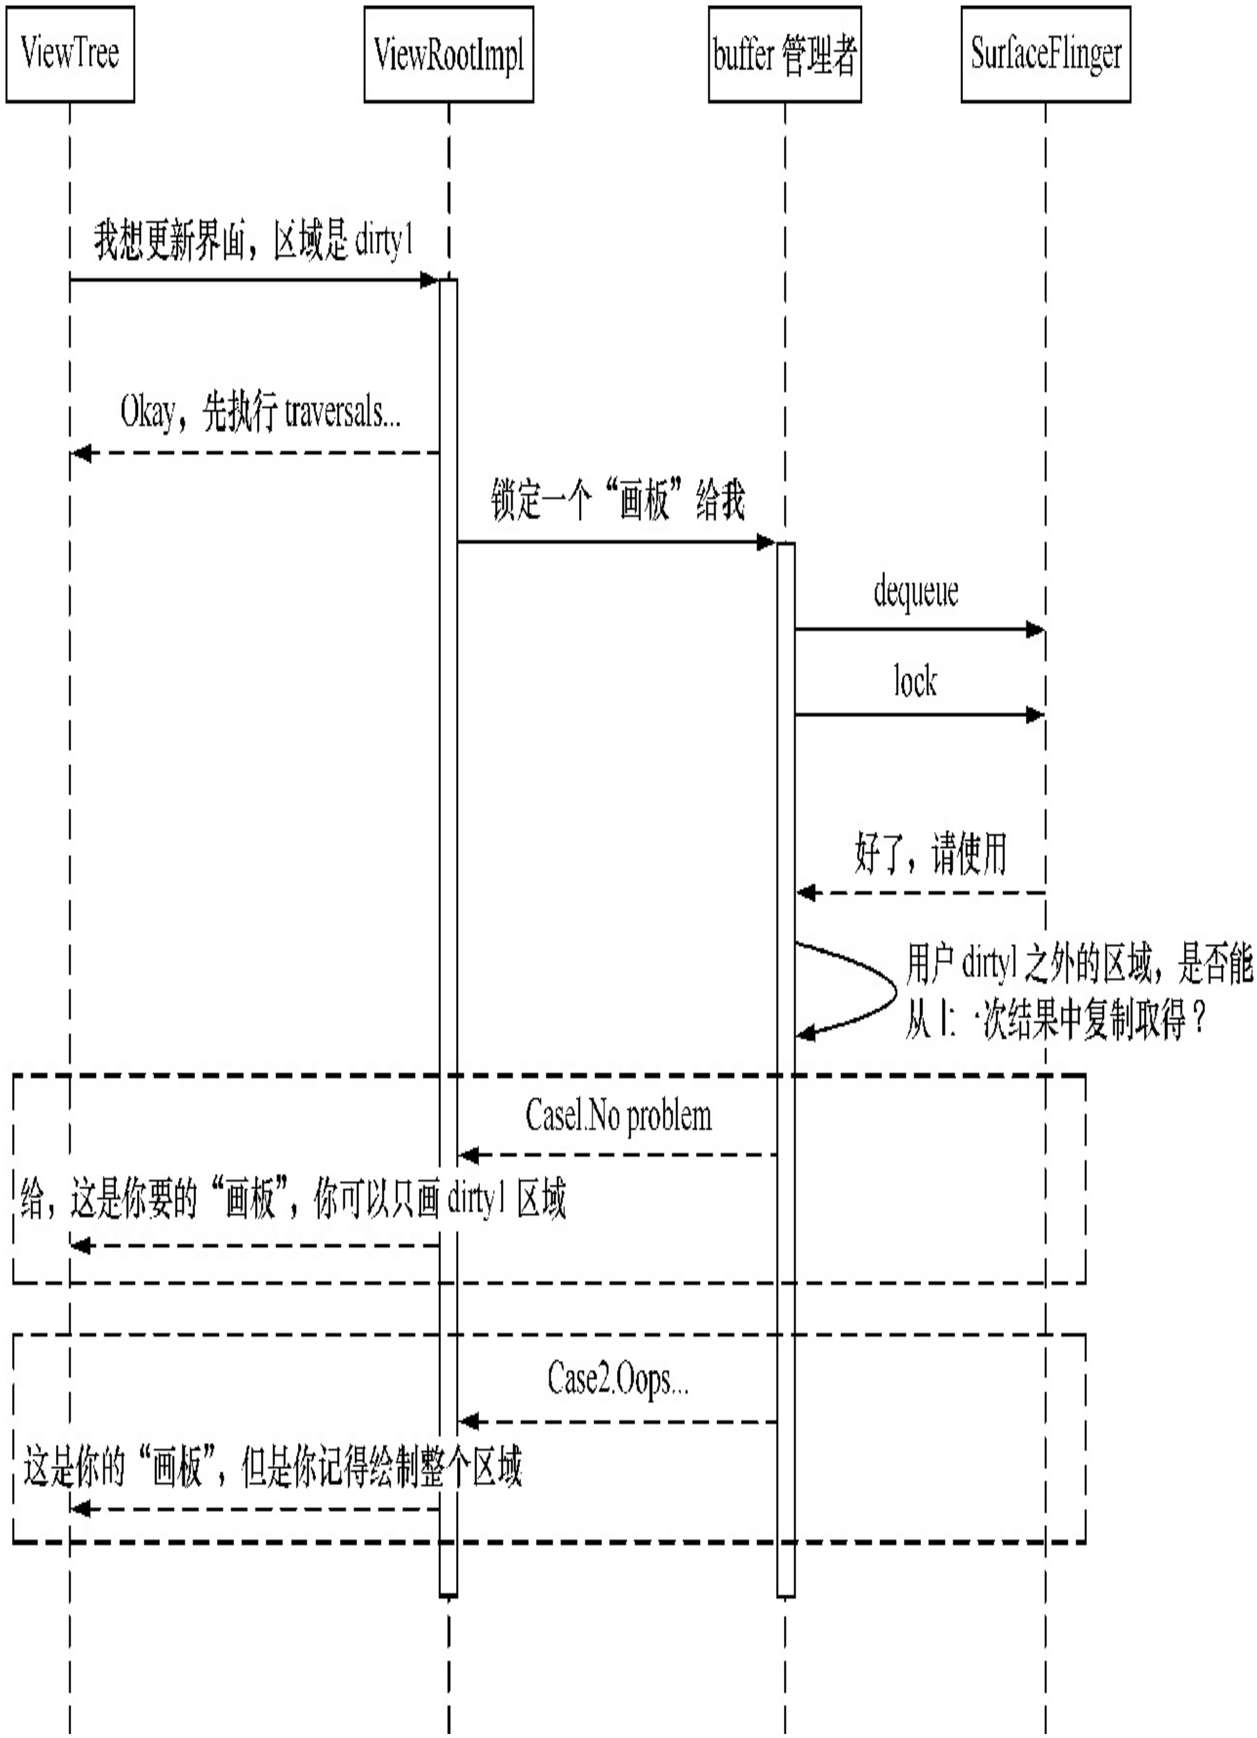
ViewTree
ViewRootImpl
buffer 管理者
SurfaceFlinger
我想更新界面，区域是 dirty1
Okay，先执行 traversals...
锁定一个“画板”给我
dequeue
lock
好了，请使用
用户 dirtyl 之外的区域，是否能
从上一次结果中复制取得？
Casel.No problem
给，这是你要的“画板”，你可以只画 dirty1 区域
Case2.Oops...
这是你的“画板”，但是你记得绘制整个区域

▲图11-25 围绕绘图板展开的对话

Step7@Surface::lock。锁定这个buffer，以防止别人使用。可以参见前面SurfaceFlinger章节关于BufferSlot生命周期的讨论。

Step8@Surface::lock。当前被锁定的buffer，即mLockedBuffer可以通过backBuffer来赋值；另外，lock函数的计算结果需要告知调用者，包括申请到的buffer的属性（宽、高等），存储UI数据的内存块首地址bits等，这些都通过outBuffer函数出参传递给上层用户。

11.8.3 解锁并提交结果——unlockCanvasAndPost

一旦UI绘图完成，程序需要将这幅“画”解锁，并提交给系统进行渲染——这里的系统具体指的是SurfaceFlinger这个服务。

Surface提供了与前一小节lock（可能命名为“lockCanvas”会更贴切）相配套的unlockCanvas AndPost，以便ViewRootImpl在performDraw遍历后，可以利用这个接口来告知Surface一个完整的绘图操作已经完成。这个函数的Java层实现很简单，读者可以自行分析。我们直接看它在JNI中的实现：

```
/*frameworks/base/core/jni/android_view_Surface.cpp*/
static void nativeUnlockCanvasAndPost(JNIEnv* env, jclass clazz,
    sp<Surface> surface(reinterpret_cast<Surface *>(nativeObject)
    …
    status_t err = surface->unlockAndPost();
    …
}
```

JNI层的nativeUnlockCanvasAndPost又调用了Surface(C++)提供的unlockAndPost：

```
/*frameworks/native/libs/gui/Surface.cpp*/
status_t Surface::unlockAndPost()
{
    if (mLockedBuffer == 0) {//当前是否有可用的Buffer
        ALOGE("Surface::unlockAndPost failed, no locked buffer");
        return INVALID_OPERATION;
    }
    status_t err = mLockedBuffer->unlock();//Buffer解除锁定
    err = queueBuffer(mLockedBuffer.get());//Buffer入队
```

```
    mPostedBuffer = mLockedBuffer;
    mLockedBuffer = 0;
    return err;
}
```

第一步判断mLockedBuffer是否为空，这个变量代表当前被锁定的buffer，在前面分析的Surface::lock函数中分配。假如mLockedBuffer==0，程序即刻出错返回。

接着，mLockedBuffer通过unlock来解锁，这个函数是与上一小节Step7中的backBuffer->lock相对应的。执行完unlock后，现在可以把buffer入队了，即queueBuffer。SurfaceFlinger便可以在后续的合成中对这一buffer进行处理，并最终将其显示到屏幕上。最后，mPostedBuffer记录下已经提交成功的buffer，这将作为下一次lock时的参考；而mLockedBuffer会被清零，以等待新的lock请求。

11.9 draw和onDraw

学习完Canvas的实现机制后，现在可以把重心再放到Java应用层。

我们知道，ViewRootImpl的遍历分为3步，即performMeasure、performLayout和performDraw。前两步我们都已经完整分析过，还剩下最后也是最关键的一个环节，即应用程序配合执行performDraw的过程。

那么，View对象绘制图形的一般流程是怎样的呢？

一旦ViewRootImpl成功lock到Canvas，它就可以通过ViewTree的根元素逐步把这个“画板工具”往下传输。因而第一个被处理的元素是最外围的Décor View（针对PhoneWindow的情况），如下所示（假设是在软件渲染的情况下）：

```
private boolean drawSoftware(…) {…
    mView.draw(canvas);
    …
}
```

变量mView是ViewRootImpl内部用于记录ViewTree根元素的成员变量，它的draw函数就是整棵ViewTree绘图遍历的起点。另外，虽然Decor View是ViewGroup，但并不重载draw方法，所以上述代码段中还是调用了View.draw。

在分析源码前先来思考一下：如果你是View的设计者，将如何编排这个draw函数呢？至少有两个大方向要特别注意：

- draw与onDraw的分离

因为后续的View子类希望只重载onDraw，而不是整个draw函数。这就给我们提出了强制性要求，即View的draw函数设计要具有共性——因为我们没有办法预先知晓所有扩展子类的行为。

- draw中的绘图顺序

View中包含的UI内容很多，绘图是否有特定的顺序？如图11-26所

示。

我们知道，一个典型View对象所描述的UI界面通常如图11-27所示。

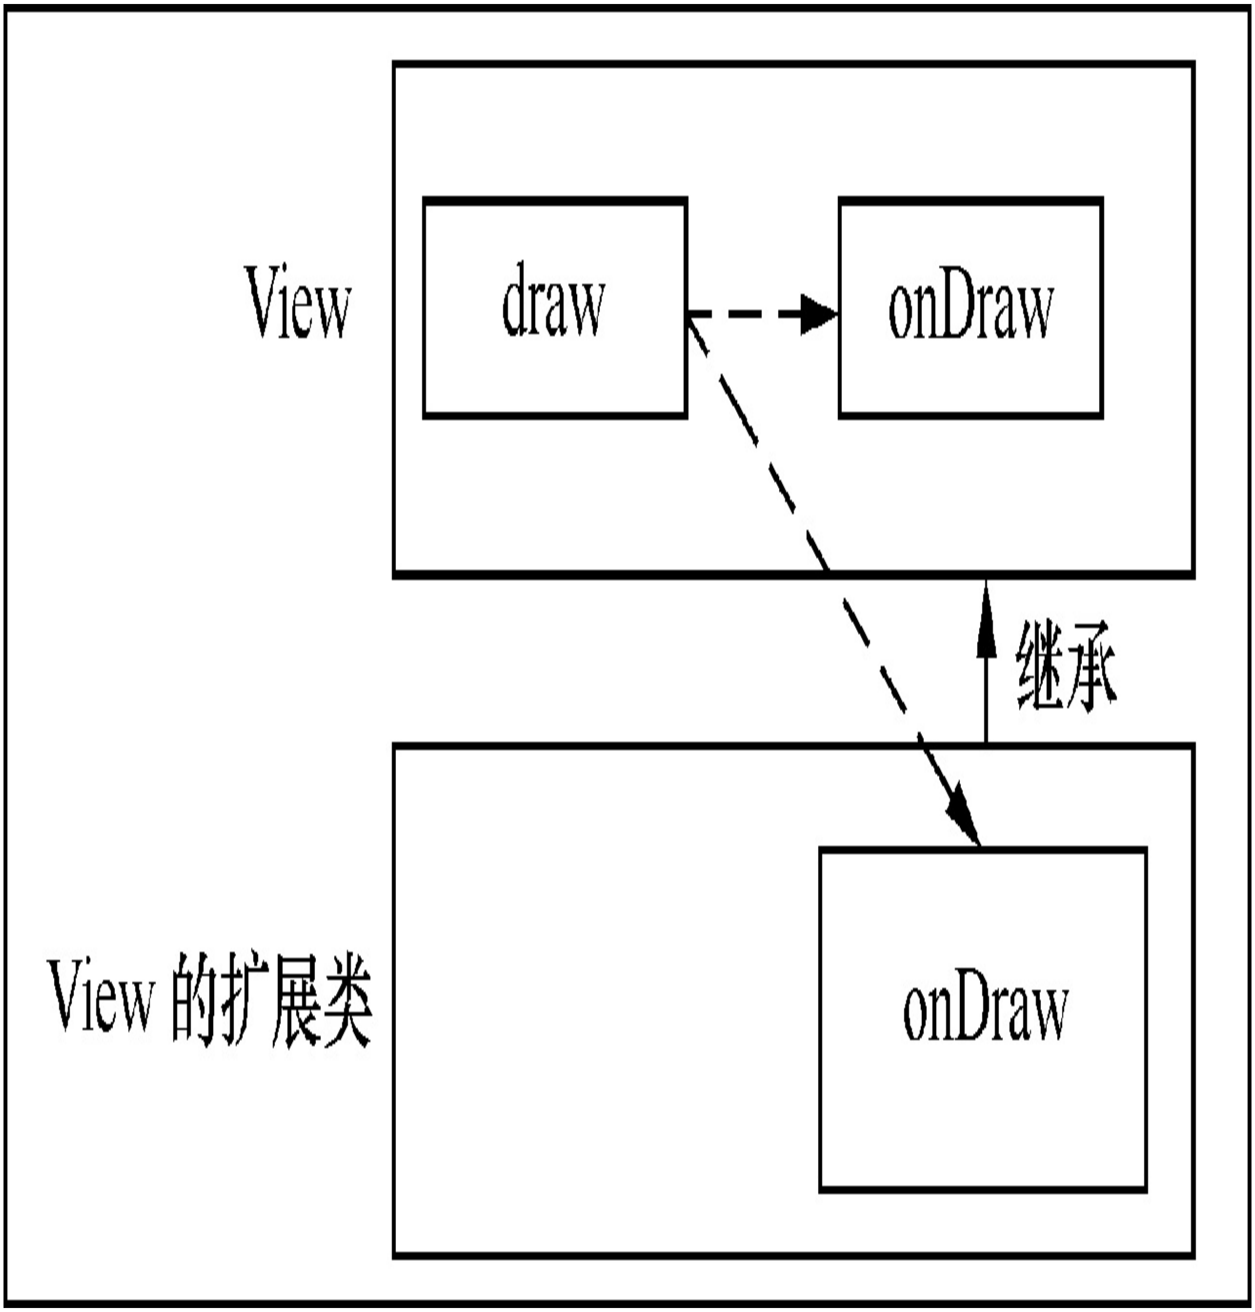

▲图11-26　onDraw函数

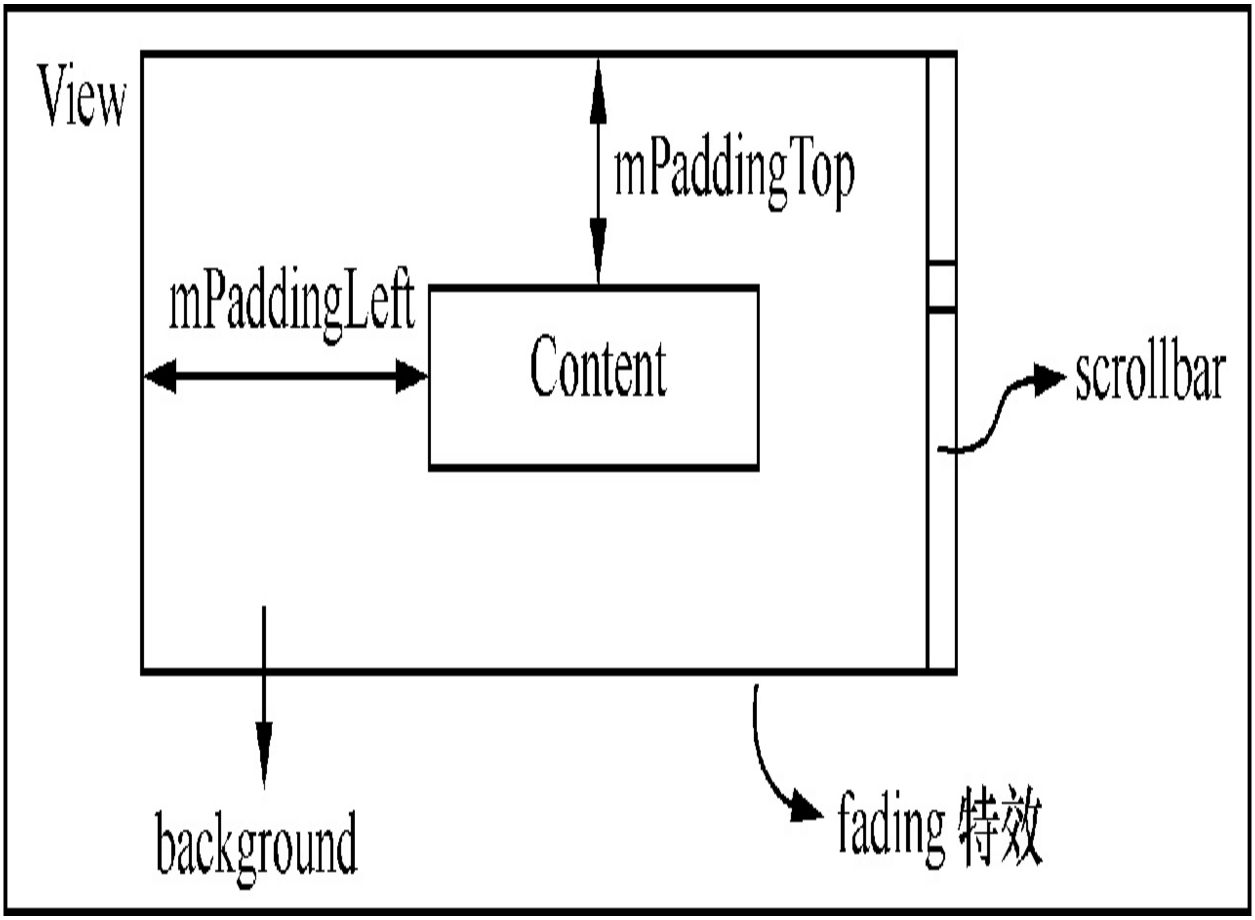

▲图11-27 View所表达的UI界面

也就是说，View类中有如下UI元素。

- background

View视图通常需要设置一个背景，如一张图片。

- content

内容区域是这个View真正想表达的画面，所以是重中之重。根据以前的分析，这个区域与外边框通常情况下会有一定的距离，即padding。

- decorations

主要是指scrollbar。滚动条分为垂直和水平两种，位置也是可以

调整的。

- fading

为了呈现比较好的UI效果，我们也可以选择给View视图增加fading特效。

带着这些基础知识，我们来看看View类中draw函数的源码实现：

```
public void draw(Canvas canvas) {…
    final int privateFlags = mPrivateFlags;
    final boolean dirtyOpaque = (privateFlags & PFLAG_DIRTY_M
      PFLAG_DIRTY_ OPAQUE&& (mAttachInfo == null || !mAttachI
    mPrivateFlags = (privateFlags & ~PFLAG_DIRTY_MASK) | PFLA
    // Step 1.绘制背景：
    int saveCount;
    if (!dirtyOpaque) {
        …//具体代码稍后分析
    }
    /*接下来分为两种情况：要么完整执行Step2-6;要么跳过其中的Step2和St
    的详细说明，请结合起来阅读)*/
    final int viewFlags = mViewFlags;
    boolean horizontalEdges = (viewFlags & FADING_EDGE_HORIZO
    boolean verticalEdges = (viewFlags & FADING_EDGE_VERTICAL
    if (!verticalEdges && !horizontalEdges) {//情况1. 没有fadir
        if (!dirtyOpaque) onDraw(canvas);// Step 3, 绘制内容
        dispatchDraw(canvas);// Step 4, 绘制子对象
        onDrawScrollBars(canvas);// Step 6, 绘制decoration
        …
        return;//直接返回
    }

    /*情况2. 如果程序走到这里，说明我们要完整执行Step2-Step6(uncommc
    …//具体代码略
}
```

在阅读上面源码的过程中，首先要抓住一个重点，即它的绘制顺序是怎样的。我们已经对每一个步骤都做了注释，总的来说是：

（1）绘制背景。

显然背景在最底层，会被其他元素所覆盖，因而需要最先被绘制。

（2）保存canvas的layers，以备后续fading所需。

（3）绘制内容区域。

（4）绘制子对象（如果有的话）。

（5）绘制fading（如果有的话），restore第（2）步保存的layers。

（6）绘制decorations（主要是scrollbars）。

上述6个步骤并不是每次draw过程都会被全部执行。比如step 2和step5对于很多应用程序来讲都是可选的，并不需要考虑。由此，整个draw函数分为两种Cases。

Case1(Common Case)：假如horizontalEdges和verticalEdges都为空，那么可以跳过第2步和第5步——这将大大简化整个函数流程。其他Steps所对应的实现分别是:

Step3: onDraw。

Step4: dispatchDraw。

Step6: onDrawScrollBars。

其中对于onDraw会在后续内容中做详细分析。而剩余Steps比较简单，大家可以自行阅读理解。

另外，第一个步骤即背景的绘制是在两种情况下都要考虑的。代码实现如下:

```
final Drawable background = mBackground;
if (background != null) {//背景资源存在
    final int scrollX = mScrollX;
    final int scrollY = mScrollY;
    …
    if ((scrollX | scrollY) == 0) {
        background.draw(canvas);
    } else {
        canvas.translate(scrollX, scrollY);
        background.draw(canvas);
        canvas.translate(-scrollX, -scrollY);
    }
```

```
}
```

背景图记录在mBackground成员变量中，所以如果这个值为空，我们就没有必要往下执行了。另一个需要考虑的是mScrollX/mScrollY，假如这两个值都为0，说明当前View还没有或者不用Scroll，这样background就可以直接绘制；否则它还应该进行必要的坐标变换（注意：background.draw结束后坐标变换需要还原回来）。

在分析onDraw具体的实现代码前，我们先通过两个小例子来帮助读者准备一些基础知识。

例1：

假设有一个LinearLayout（ViewGroup），包含了3个View对象，并且它们都平均分配空间位置（View树里每个节点的位置和空间大小的计算，在Android中有一个完整的逻辑流程。这其中涉及很多细节与用户配置，如margin，weight等。不清楚的读者可以参见前面View/ViewGroup属性的讲解。我们这里假设3个View视图所占的空间大小是平均分配的）。那么，整体效果看起来是这样的（View的大小和位置确定好后了），如图11-28所示。

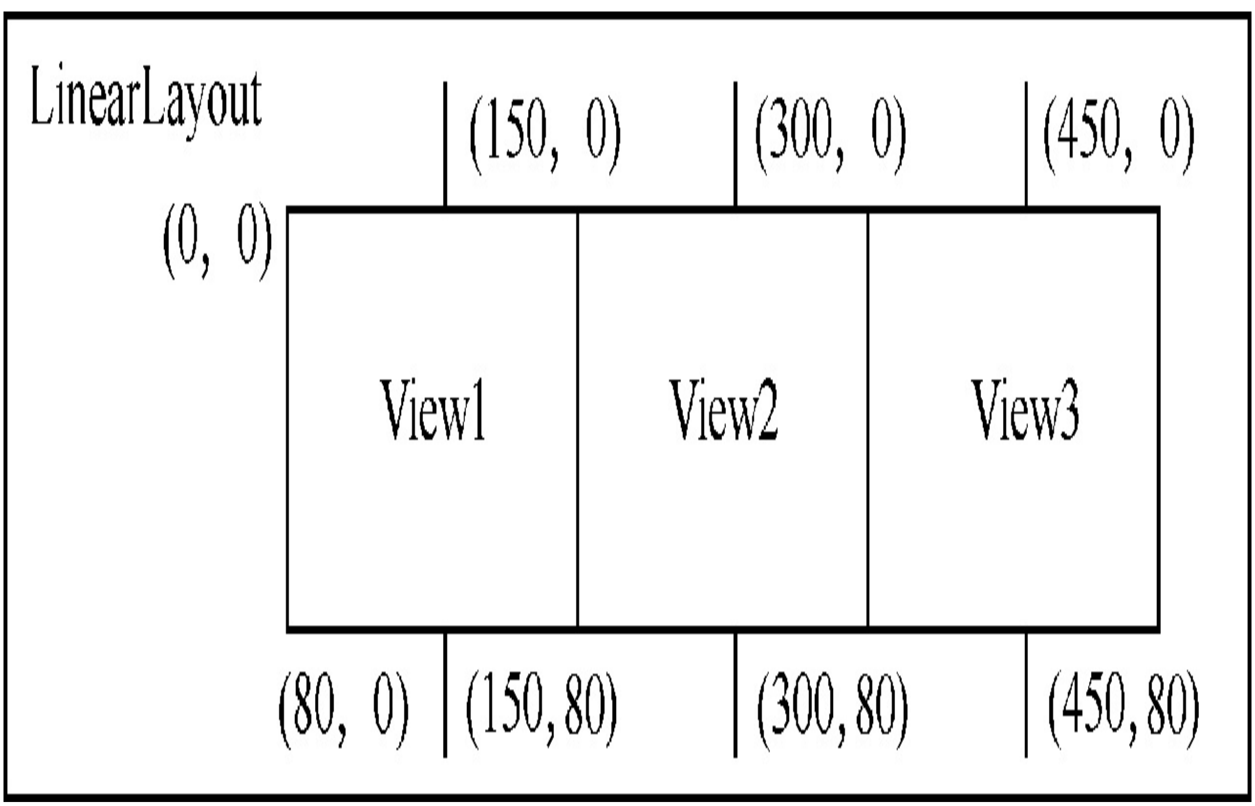

▲图11-28 确认好位置和大小后的状态

也就是说，最终每个View的大小都是150*80。我们知道，如果View对象所占的面积足够支撑它的内容区域，那么就不需要滚动条了，这样问题会简单点；否则如果内容过多，一次性无法显示完整，那情况又不一样了。以View3为TextView为例，用户在阅读一个字数较多的文本时通常需要不断滚屏来浏览全文，如图11-29所示。

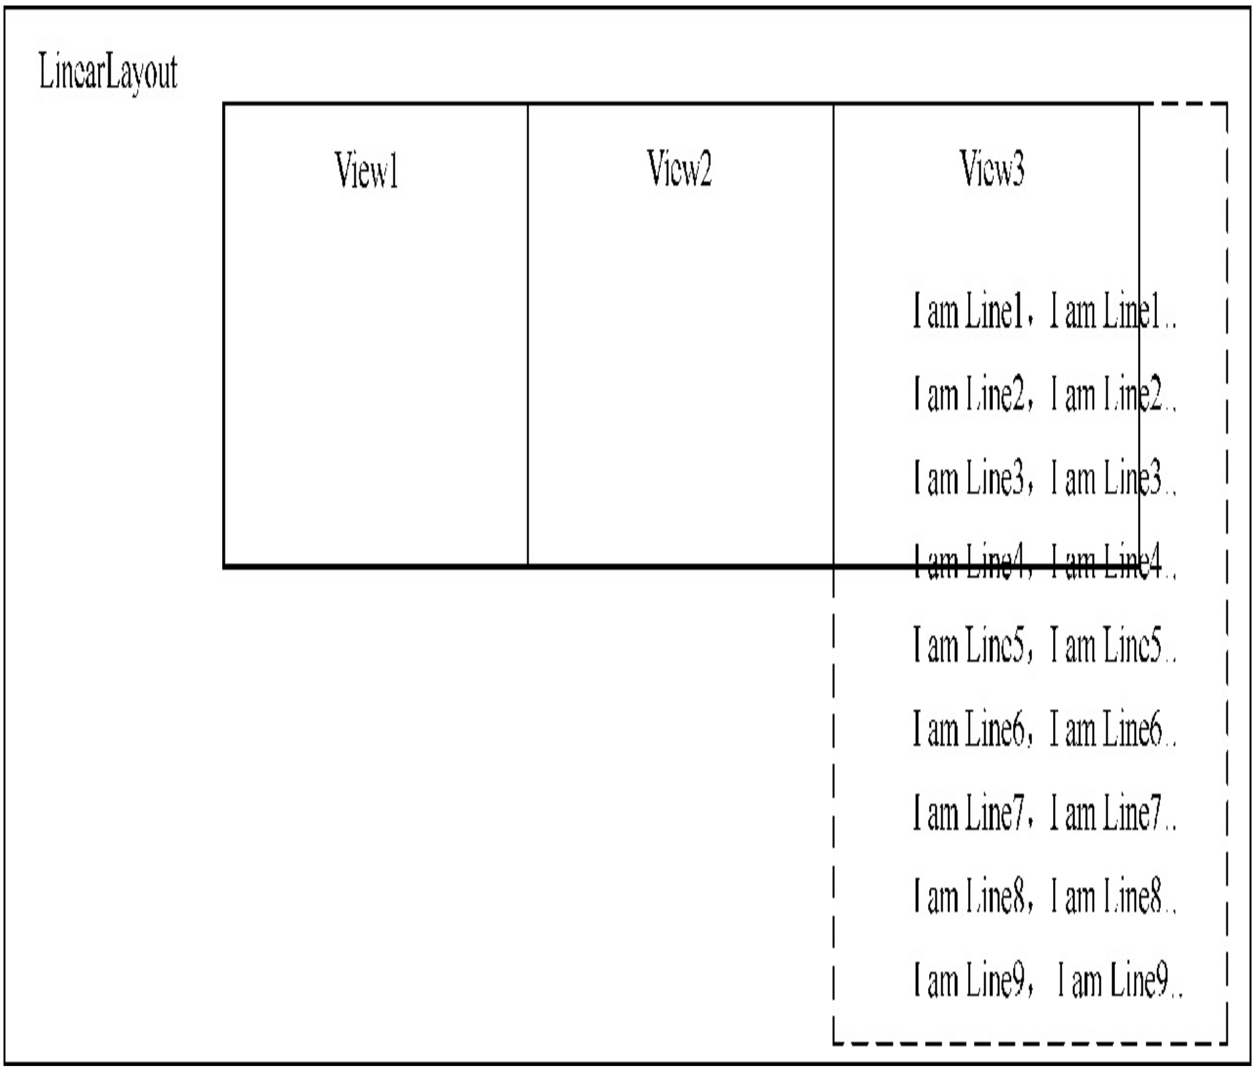

▲图11-29　TextView起始状态

如图11-29所示，是TextView的起始状态，即还没有操作滚动条时的效果。因为整个文本超出了View3的可视范围，用户在阅读过程中肯定需要不断调整滚动条来获取他所需要的信息，如图11-30所示。

可以看到，当滚动条起作用后，文本的起点位置不再与View3的起始原点重合。这时View中的内部变量mScrollX和mScrollY也会被赋予相应的值。通过这个小例子，我们明白了以下几点。

- 每个View的大小都会受到其他View的制约

假设View的大小是wrap_content的，那么父类会根据其所有子类的实际情况，为这个View分配相应的大小。View也可以强制指定所需的空间大小，不过能否最终满足，还依赖于其他View的配置。总之，分配过程遵循“尽可能满足所有View的需求，但又公平、合理”的原则进行。具体细节可以参见前面小节对遍历流程的分析。

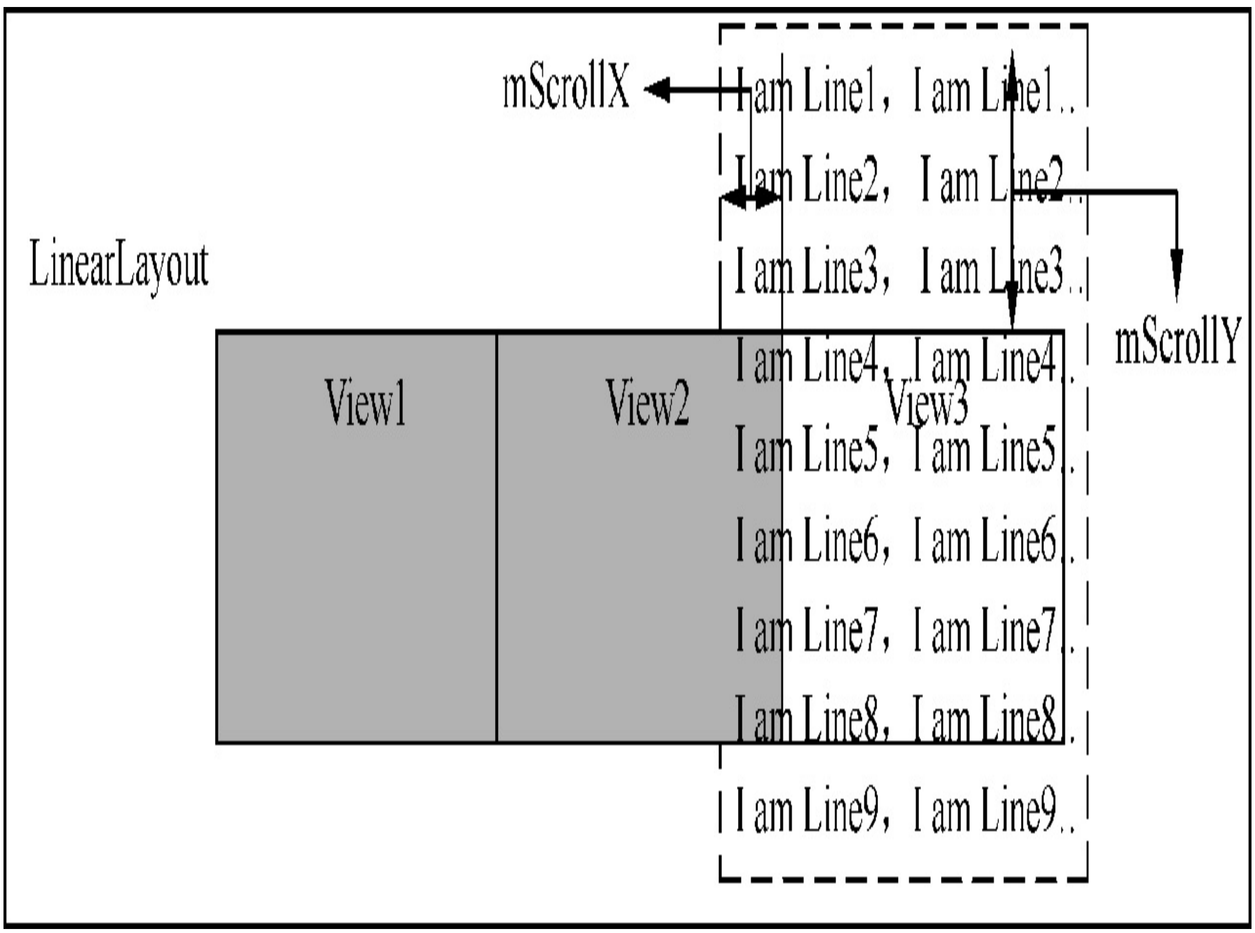

▲图11-30　TextView的滚动条效果

- View的“潜在”显示内容有可能超过其可视区域

View的大小是有限制的，而“显示内容”理论上是无限的。比如字数众多的一个Text文本，即便我们给它整个屏幕空间，也未必能一次性全部显示出来。所以，View内带有滚动条操作是合理而且必需的。在理解滚动、View以及内容之间的关系时，我们可以这样想：

- View的可视区域是不变的。也就是说，上面View3的可视区间是父类分配的，为（Left:300，Top:0，Right:450，Bottom:80）。这个区域是客观存在的，并不会随着View3本身的“意志而转移”（比如View3拉动了滚动条，并不会改变它的显示区域。当然，如果是View3主动向父类发起了layout变更请求，而且父类也同意了，那么这个区域是会变化的。不过这也会影响到其他View的位置和大小，所以一定会引起ViewRootImpl对ViewTree进行重新遍历）。

- 当滚动条操作时，显示内容会发生变化。这就像用眼睛看世界一样，世界是无穷大的，但我们可以看到的视野是有限的，因为眼球的“可视区域”就那么大。虽然无法改变这个可视范围的大小，但我们通过转动脖子，却可以获取到整个世界的“内容”，这就足够了。

明白了以上几点后，我们再来小结下View要怎么做才可能满足上面的需求。

- 当一个View对象经过ViewRootImpl的统一遍历后，它会有固定的大小及位置。
- View应该有一个初始界面。这就好比我们每天早上睁开双眼看到的第一个画面一样。而且在一段时间内，第一个画面并不会改变。就好像你只是睁开了双眼，但还是赖在床上一动不动，那么你看到的东西多半是不变的。当然，如果你看到的是家里的小狗，那么即便你自己不动，也不能保证它摇动尾巴而带来的画面更新（这个其实类似于View中动画的实现原理）。大家可以再体会一下其中的关系。
- 什么情况下画面会动？可能是View收到了外部事件触发了它“动的欲望”（比如用户拉动了滚动条，或者收到了外部硬件事件。那么在响应事件的同时，很可能就会更新画面）；当然也可能是前面所说的“动画”机制从内部产生的触发事件。

- View经过判断发现必须更新画面后，它会首先计算出需要重绘的dirty区域，然后沿着ViewTree不断往父对象发起界面刷新请求——最终由ViewRootImpl来主导整个过程。

例2：

前一个例子我们通过一个TextView了解了滚动条操作的处理过程。为了保持连贯性，还是接着上面的图例进行分析，如图11-31所示。

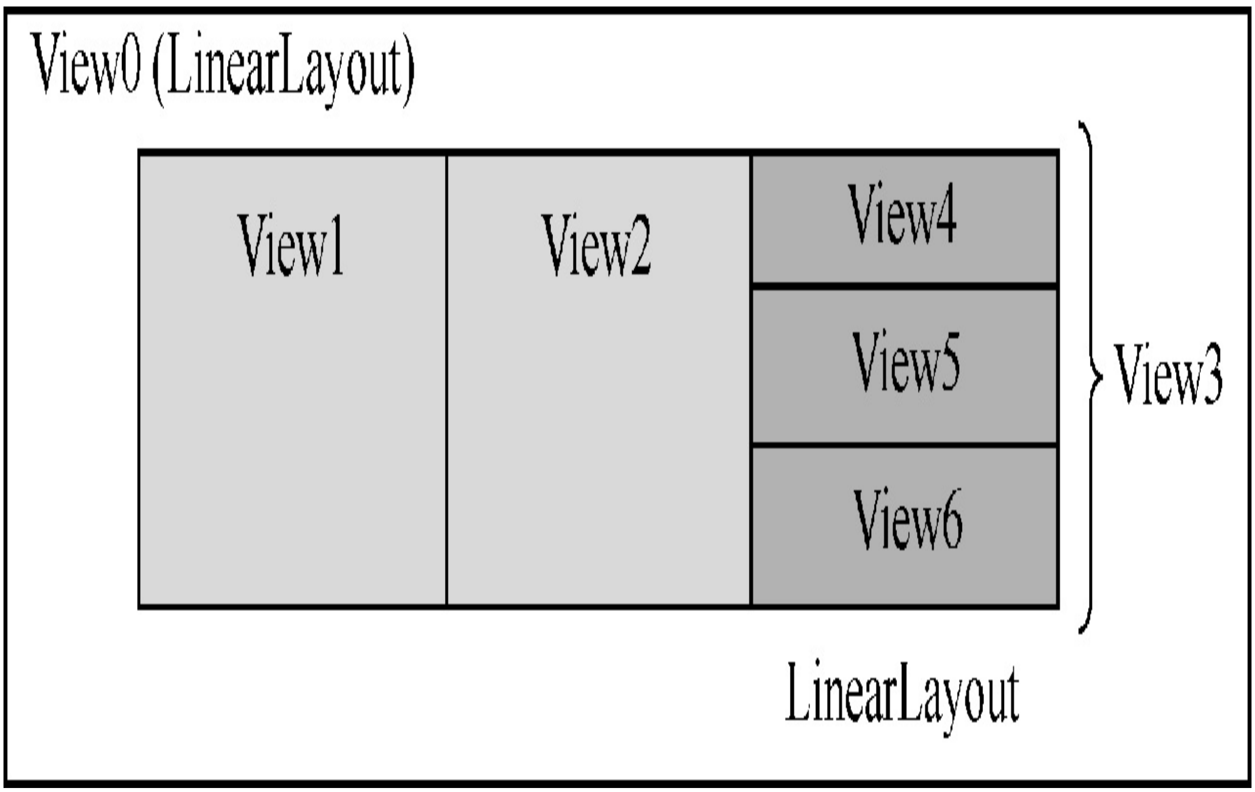

▲图11-31　View3也是ViewGroup的情况

假设View3不再是TextView，而是和它的父类一样的LinearLayout（继承自ViewGroup）。它包含了3个子View（View4～View6）。也就是说，这棵View树暂时是这样的，如图11-32所示。

图11-32中的ViewTree相比例子1又复杂了点，不过与大多数应用程序中真正的ViewTree相比还有一定差异。换句话说，ViewTree拥有的树叶节点理论上是没有上限的。当draw函数由树根节点（即图中的View0）逐步往下递归调用时，问题就来了：是不是所有的树叶节点都

会被遍历到呢？

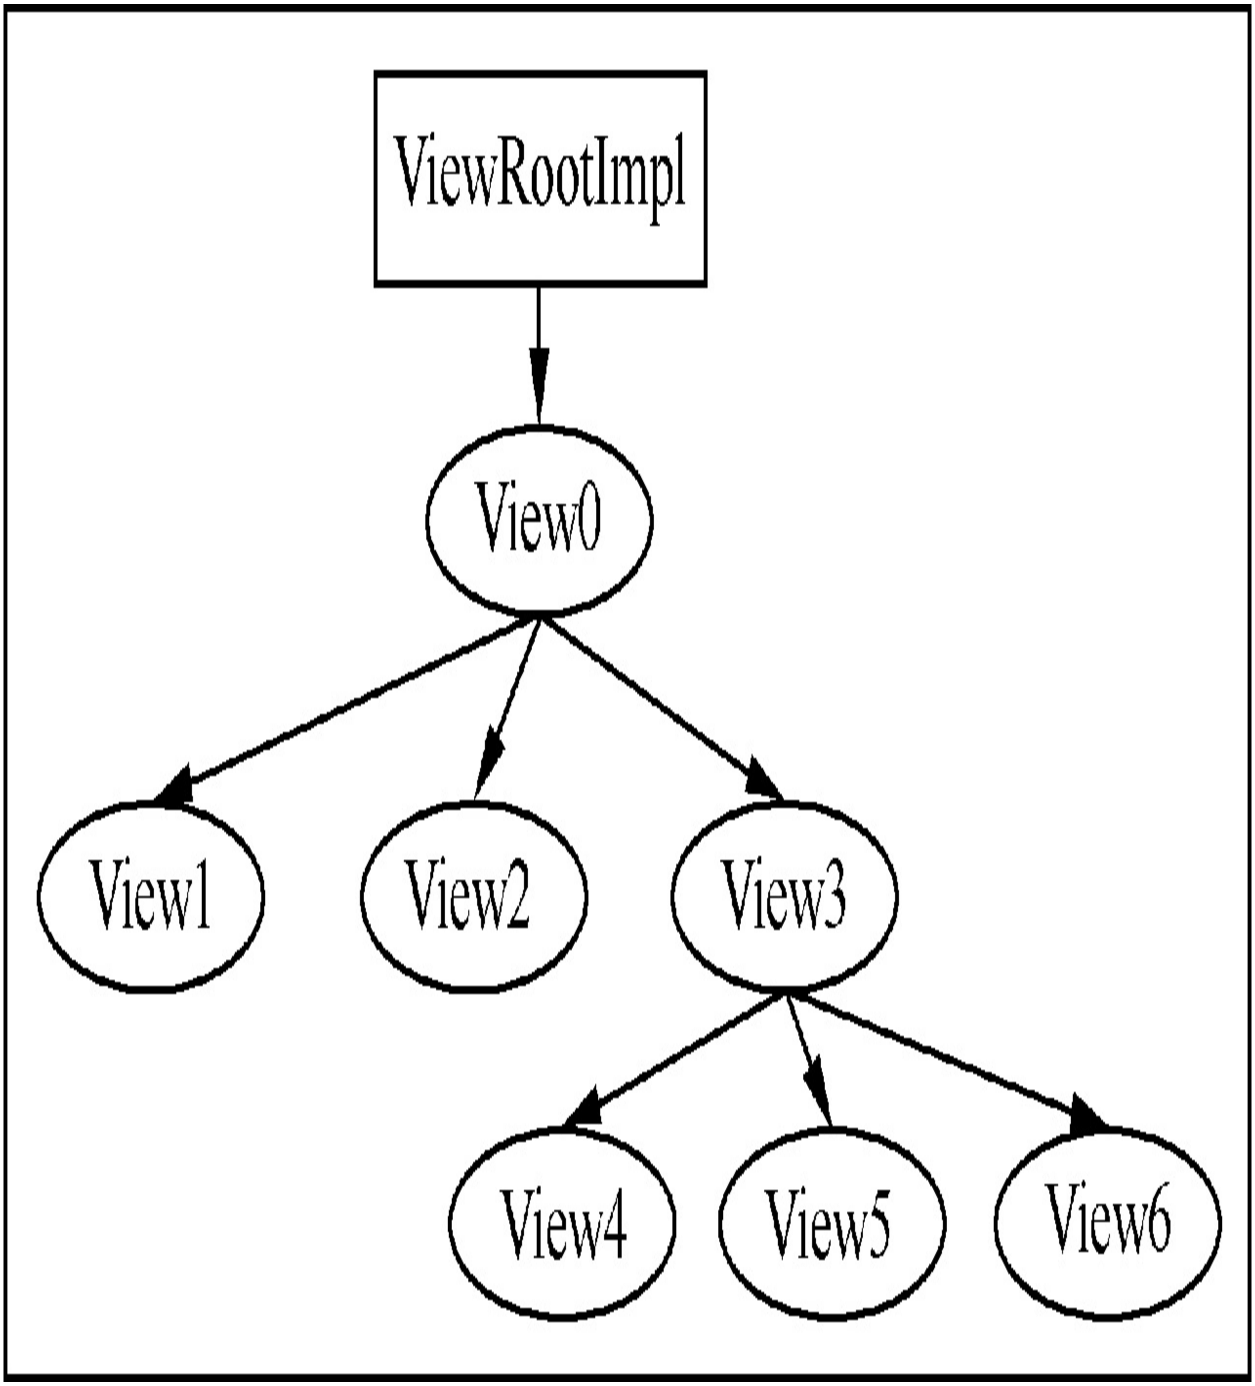

▲图11-32 例2中的View树

答案是“不一定”。对于那些界面没有任何变化的View对象，我们没有必要浪费资源去进行重绘。为了达到这一目标，就要求View的父对

象，如View0之于View1～View3，或者View3之于View4～View6，可以严格把控住整个draw流程。我们在进行应用程序开发时，尤其是扩展了一个View/ViewGroup类时，也需要特别注意这一点。

接下来我们以ImageView为例，来分析onDraw的源代码实现：

```
/*frameworks/base/core/java/android/widget/ImageView.java*/
protected void onDraw(Canvas canvas) {
    super.onDraw(canvas);
    if (mDrawable == null) {//如果Drawable为空，直接返回
        return; // couldn't resolve the URI
    }
    if (mDrawableWidth == 0 || mDrawableHeight == 0) {//且Draw
        return;     // nothing to draw (empty bounds)
    }
    if (mDrawMatrix == null && mPaddingTop == 0 && mPaddingLe
        mDrawable.draw(canvas);
    } else {
        int saveCount = canvas.getSaveCount();
        canvas.save();//保存这一场景，稍后还要恢复
        if (mCropToPadding) {
            final int scrollX = mScrollX;
            final int scrollY = mScrollY;
            canvas.clipRect(scrollX + mPaddingLeft, scrollY +
                    scrollX + mRight - mLeft - mPaddingRight,
                    scrollY + mBottom - mTop - mPaddingBottom
        }

        canvas.translate(mPaddingLeft, mPaddingTop);//坐标变换
        if (mDrawMatrix != null) {
            canvas.concat(mDrawMatrix);
        }
        mDrawable.draw(canvas);
        canvas.restoreToCount(saveCount);//恢复Canvas
    }
}
```

首先进行合法性判断，即ImageView必须持有一个尺寸大小正常的mDrawable，否则直接返回。随后的情况分为两种：

1．不需要坐标变换的情况

也就是说同时满足mDrawMatrix == null && mPaddingTop == 0 && mPaddingLeft == 0。

那么这是最简单直接的一种场景，我们只要调用mDrawable.draw(canvas)，由Drawable来将其图像写入Canvas中即可。

2．需要坐标变换的情况

只要mDrawMatrix、mPaddingTop或者mPaddingLeft有任何一个不为空，那么我们就进入第二种情况。和在其他地方的处理类似，此时要先保存Canvas的状态，以备后续恢复。

变量mCropToPadding可以由android:cropToPadding属性来配置，代表image是否要裁剪以适应padding。如果是，进行相应的clipRect操作。

接着，Canvas要通过坐标变换来跳过padding部分的绘制，即canvas.translate(mPaddingLeft，mPaddingTop)；如果mDrawMatrix不为空，我们还要concat这一部分已经存在的matrix。最后，才能调用mDrawable.draw(canvas)将Drawable中的内容绘制到Canvas上。经过上面的努力，此时图像内容就可以按照要求“画”到指定的位置上了。

11.10 View中的消息传递

在项目开发过程中，View中的消息传递流程也是一个重点和难点——onInterceptTouchEvent，onTouchEvent，onClick，onLongClick等一系列接口方法很容易让人混淆。

读者可以先试想一下，对于一棵View树来说，它的消息传递应该是自上而下，即从根节点开始逐层往子类递归传递的。在消息流转过程中，一旦有人处理了这个消息，那么传递即可宣告中止（除非有特殊需求）。从这一点来看，View树的上层拥有消息处理的优先权。

从理论的角度来讲，因为我们预先并不知道树的节点是View还是ViewGroup，因而递归过程中所调用的接口必定是由View提供的，然后由ViewGroup来重载。

当前Android系统所能处理的外部事件基本涵盖了市面上常见的输入设备，如触摸屏、按键、鼠标等。我们将在后续章节对系统的输入设备管理机制进行详细的分析，而本小节的重点是View和ViewGroup内部是如何处理Input Events的。为了使讲解更具针对性，接下来的内容以TouchEvent为主，并分别从View和ViewGroup两个方面来剖析问题。

11.10.1 View中TouchEvent的投递流程

我们先概括下View类对整个输入事件的处理流程，如图11-33所示。

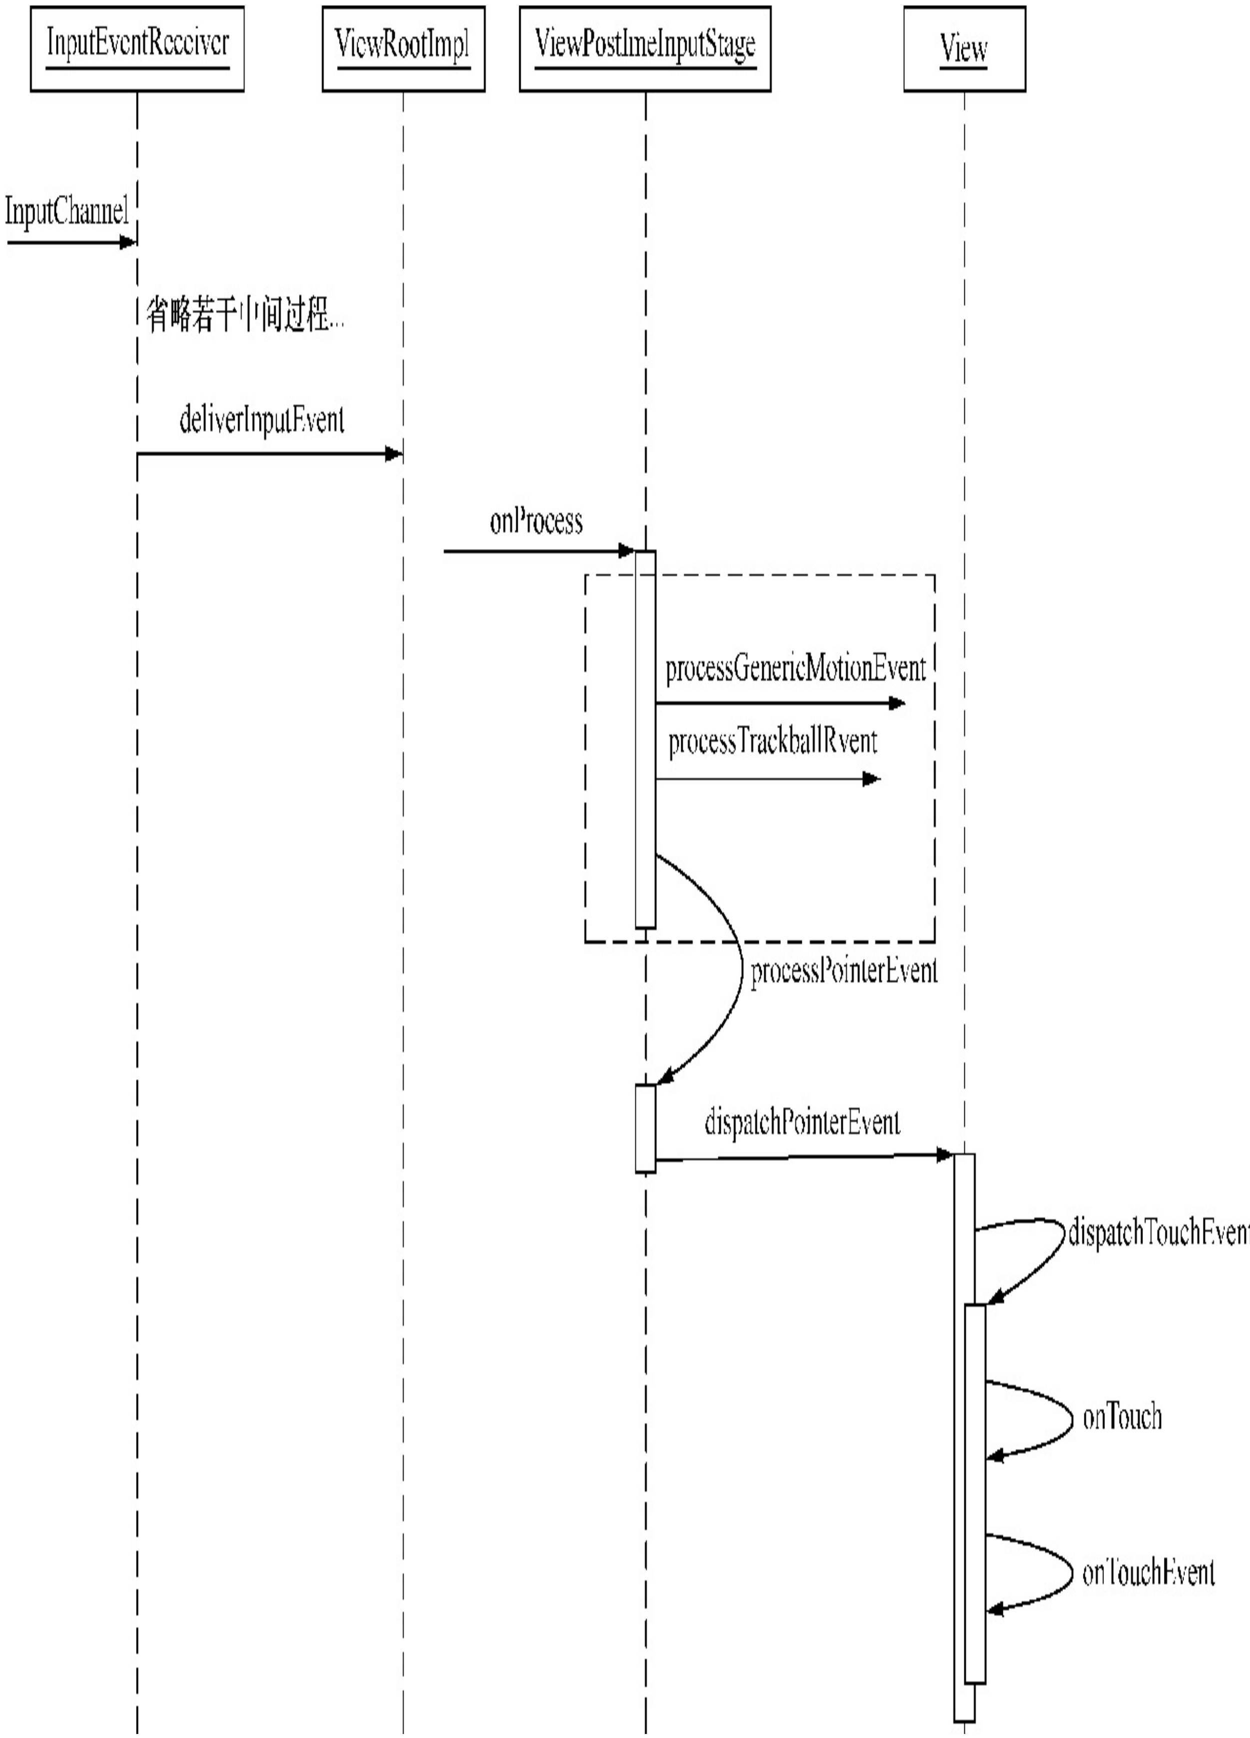

InputEventReceiver
ViewRootImpl
ViewPostImeInputStage
View
InputChannel
省略若干中间过程...
deliverInputEvent
onProcess
processGenericMotionEvent
processTrackballRvent
processPointerEvent
dispatchPointerEvent
dispatchTouchEvent
onTouch
onTouchEvent

▲图11-33　View类的事件处理流程图

ViewRootImpl在Jelly Bean几个版本中改动较大。最新的Android系统中，事件的处理者不再由InputEventReceiver独自承担，而是通过多种形式的InputStage来分别处理，如SyntheticInputStage、ViewPostImeInputStage、NativePostImeInputStage、EarlyPostImeInputStage等。这些InputStage都重载了一个接口，即onProcess。以ViewPostImeInputStage为例：

```
protected int onProcess(QueuedInputEvent q) {
    if (q.mEvent instanceof KeyEvent) {
        return processKeyEvent(q);//按键事件
    } else {
        final int source = q.mEvent.getSource();
        if ((source & InputDevice.SOURCE_CLASS_POINTER) !=
            return processPointerEvent(q);
        } else if ((source & InputDevice.SOURCE_CLASS_TRACK
            return processTrackballEvent(q);
        } else {
            return processGenericMotionEvent(q);//Motion事件
        }
    }
}
```

由此可见，当系统判断出当前是SOURCE_CLASS_POINTER类型的事件后，将调用process PointerEvent做进一步处理。这个函数会把这一处理权移交给View Tree的根元素，即mView的dispatchPointerEvent接口，然后由后者再细化判断。

- 是否Touch Event

  是的话就调用dispatchTouchEvent。

- 否则就是Generic Motion Event

  此时调用dispatchGenericMotionEvent。

从名称就可以看出来，这些函数负责“分发”事件，它们将决定Event的后续流向：

```
/*frameworks/base/core/java/android/view/View.java*/
    public boolean dispatchTouchEvent(MotionEvent event) {…
        if (onFilterTouchEventForSecurity(event)) {
            ListenerInfo li = mListenerInfo;
            if (li != null && li.mOnTouchListener != null && (mVi
                      == ENABLED&& li.mOnTouchListener.onTouch(th
                return true;
            }
            if (onTouchEvent(event)) {
                return true;
            }
        }
        …
        return false;
    }
```

可以看到，View类中分发TouchEvent还是比较简单的，主要考虑了以下两个因素。

- onTouch

View对象可以通过setOnTouchListener来设置一个Event的监听者，这样当事件来临时，View会主动调用这个listener来告知对方。从优先级来看，这种方式较下面的onTouchEvent先行处理。

- onTouchEvent

假如用户没有指定TouchListener，或者flags中指明被disabled，又或者onTouch的返回值为false（代表这一事件没有被处理），那么系统会将event传递给onTouchEvent。

上述两种方式都是我们在应用开发中经常使用的，它们各有特色。其中onTouch更为简捷高效，而后者则更适用于View扩展类的情况（重载onTouchEvent）。在这里，onTouchEvent充当了一个“内政处理者”的角色。源码如下（分段阅读）：

```
    public boolean onTouchEvent(MotionEvent event) {
        final int viewFlags = mViewFlags;
        if ((viewFlags & ENABLED_MASK) == DISABLED) {//当前View被d
            if (event.getAction() == MotionEvent.ACTION_UP && (mP
                setPressed(false);
            }
            return (((viewFlags & CLICKABLE) == CLICKABLE ||
```

```
            (viewFlags & LONG_CLICKABLE) == LONG_CLICKABL
    }
```

这段代码说明，即便在View被disabled的情况下，它同样会消耗这个事件——只是不做出任何回应而已。这就好比快递一样，“包裹”已经正确传递到目的地，而如何处理它则是目标自己的事情了——它甚至可以选择丢弃“包裹”，但前提是必须先“签收”。

如果View没有被disabled，那么接下来程序将具体处理这一Touch事件。我们知道，一个TouchEvent还可以细分为多种类型，即ACTION_UP，ACTION_DOWN，ACTION_CANCEL和ACTION_MOVE等。

1．ACTION_DOWN

按照人体的正常操作顺序，触摸事件的序列流通常都是DOWNUP或者DOWNMOVE UP。可以看出DOWN是后续事件的“起点”，所以它通常在程序中被作为一种特殊的标志：

```
case MotionEvent.ACTION_DOWN:
    mHasPerformedLongPress = false;//置初值false
    …
    setPressed(true);//当前状态变为Pressed
    checkForLongClick(0);//检查是否常按
    break;
```

在DOWN事件的处理中，setPressed用于指示View对象是否要进入Pressed状态。如果此View对象设计了不同press状态下的差别显示（如Button控件在Pressed与Normal状态下的背景图片通常是不同的），此时就需要刷新UI，具体的处理函数是refreshDrawableState。另外当收到DOWN事件后，View就开始监测它会不会演变成长按事件。可以通过ViewConfiguration. getLongPressTimeout()来取得长按事件的产生标准，然后postDelayed一个CheckForLongPress的Runnable。在Timeout后（在timeout之前如果有ACTION_UP或者ACTION_MOVE产生，会通过removeLongPressCallback移除这个Runnable）系统就需要进行长按事件的处理。如果用户通过setOnLongClickListener设置了响应的函数，那么就会回调这些函数。

2．ACTION_MOVE

当手势按下后（DOWN）并拖动，就会随后产生ACTION_MOVE事件。

这个事件通常不止一个，而是随着用户的不断拖动持续产生，直到ACTION_UP或者ACTION_CANCEL：

```
case MotionEvent.ACTION_MOVE:
    final int x = (int) event.getX();//MOVE事件的x
    final int y = (int) event.getY();//MOVE事件的y
    if (!pointInView(x, y, mTouchSlop)) {//是否已经
        removeTapCallback();
        if ((mPrivateFlags & PRESSED) != 0) {
            removeLongPressCallback();
            setPressed(false);//不再是Pressed状态
        }
    }
    break;
```

上面这段代码中，pointInView用于判断当前的手势是否已经超出View的范围。如果回答是肯定，我们需要移除包括长按监测在内的一系列操作，并且View对象将退出Pressed状态。换句话说，ACTION_DOWN事件产生的高显状态（如果有的话）此时就会恢复正常。

3．ACTION_UP

ACTION_UP是手势操作的结束点。除了改变View的一系列状态外，它的另一个重要操作就是判断是否会产生Click，即开发人员setOnClick所要响应的事件。当然，并不是任何ACTION_UP都对应一个Click。比如前面如果已经产生了长按事件；或者当前不是Pressed状态等情况下都会阻碍Click的形成：

```
if (!mHasPerformedLongPress) { //已经执行过长按，
  removeLongPressCallback();
  if (!focusTaken) {
       if (mPerformClick == null) {
            mPerformClick = new PerformClick()
       }
       if (!post(mPerformClick)) {
            performClick();
       }
   }
```

需要注意的是，performClick并不会马上被调用执行，而是先通过post排队的方式处理。这样做可以让其他View状态优先得到更新处理，以保证执行Click操作时这些状态都是正确的。

4．ACTION_CANCEL

ACTION_CANCEL比较特殊，它并不由用户主动产生，而是系统在谨慎判断后得出的结果。这个事件说明当前的手势已经被废弃，后续不会再有任何与该手势相关联的事件产生。开发人员可以把它看成手势的结束标志，类似于ACTION_UP，并做好清理工作：

```
case MotionEvent.ACTION_CANCEL:
       setPressed(false);
       removeTapCallback();
removeLongPressCallback();
       break;
```

总的来说，View类的onTouchEvent处理逻辑比较简单。它一方面对原始Touch事件进行了直接的处理（DOWN，MOVE，UP等）；另一方面对各状态组合而产生的新事件（比如LongPress、Click等）也进行相应的派发和处理。

11.10.2　ViewGoup中TouchEvent的投递流程

ViewGroup与View在接收事件的流程上基本是一致的，如图11-34所示。大家可以先参考前一小节的详细描述。

ViewGroup因为涉及对子对象的处理，其派发流程没有View那么简单直接。具体来说，它重载了dispatchTouchEvent，对View提供的派发机制进行了重新规划：

```
/*frameworks/base/core/java/android/view/ViewGroup.java*/
    public boolean dispatchTouchEvent(MotionEvent ev) {…
        boolean handled = false;//event是否被处理
        if (onFilterTouchEventForSecurity(ev)) {
            final int action = ev.getAction();
            /*Step1. 判断是否DOWN事件*/
            final int actionMasked = action & MotionEvent.ACTION_
            if (actionMasked == MotionEvent.ACTION_DOWN) {//DOWN是
                cancelAndClearTouchTargets(ev);//一旦收到DOWN，先清
                resetTouchState();
            }

            /*Step2. 检查interception的情况*/
            final boolean intercepted;
            if (actionMasked == MotionEvent.ACTION_DOWN|| mFirstT
```

```
                final boolean disallowIntercept = (mGroupFlags & F
                 if (!disallowIntercept) {
                     intercepted = <strong>onInterceptTouchEvent</
                     ev.setAction(action); // restore action in ca
                 } else {
                     intercepted = false;//不需要拦截
                 }
             } else {
                 intercepted = true;//继续拦截
             }

             final boolean canceled = resetCancelNextUpFlag(this)
                     || actionMasked == MotionEvent.ACTION_CANCEL;
             final boolean split = (mGroupFlags & FLAG_SPLIT_MOTIO
             TouchTarget newTouchTarget = null;
             boolean alreadyDispatchedToNewTouchTarget = false;
             if (!canceled && !intercepted) {//Step3. 不拦截的情况
                 …//代码稍后分析
             }
          …//其他部分代码和上面是类似的，大家可以自行分析
         }
         …
         return handled;//返回处理结果
     }
```

这个函数的逻辑比较烦琐，我们先来理解一个概念——什么是Interception（拦截）。

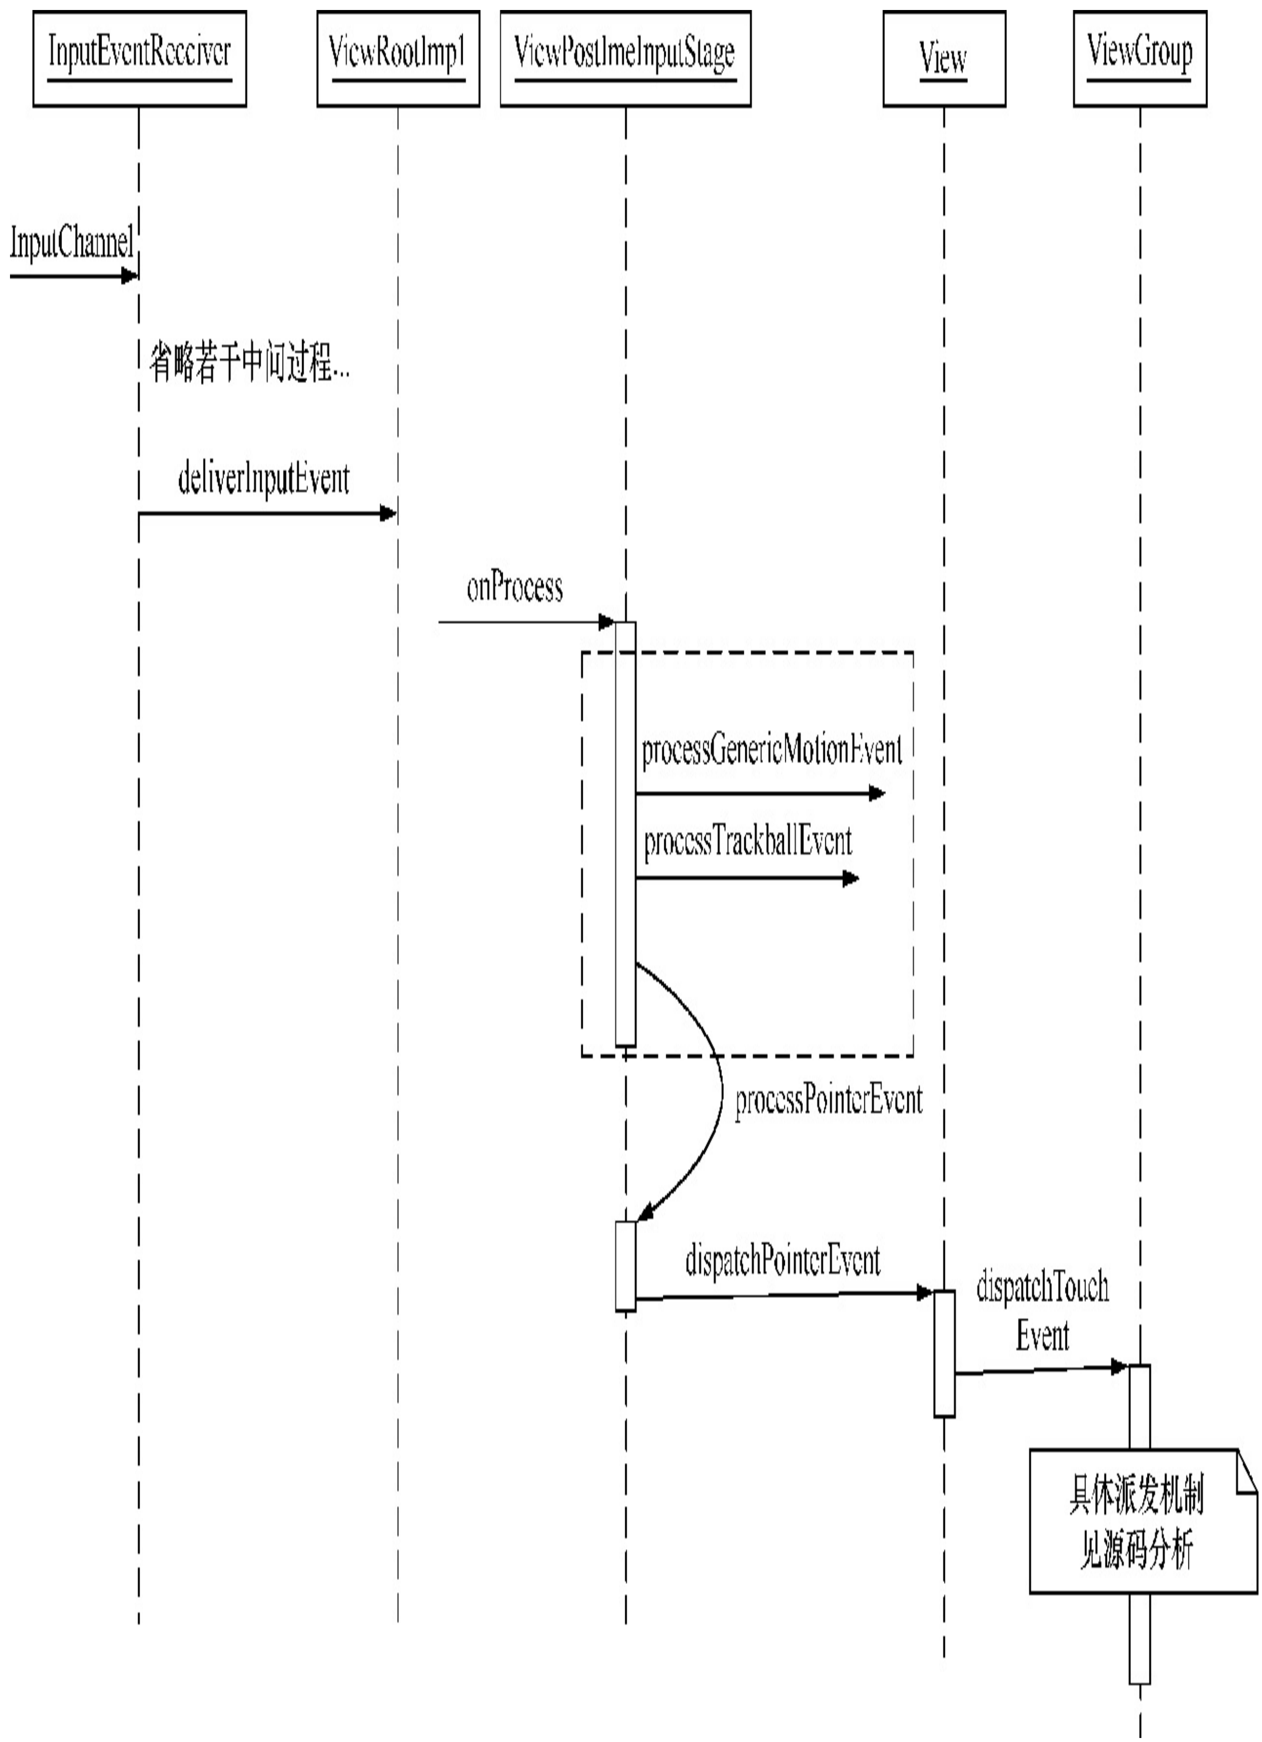

InputEventReceiver
ViewRootImpl
ViewPostImeInputStage
View
ViewGroup
InputChannel
省略若干中间过程...
deliverInputEvent
onProcess
processGenericMotionEvent
processTrackballEvent
processPointerEvent
dispatchPointerEvent
dispatchTouch
Event
具体派发机制
见源码分析

▲图11-34　ViewGroup中TouchEvent的处理

打个现实中的比方，我们从深圳寄快递到上海，中途很可能经过若干城市。那么当某个城市收到这个快递包时，它首先判断要不要把包裹拦截下来，即这个包裹是不是要由自己所在的城市进行处理。如果当前城市就是上海，那么包裹就不应该继续往下传输，继而进入由市➞区（县）➞街➞门牌号等的“内政”环节中（onTouchEvent）；而如果当前城市是除上海外的中间城市，则在收到快递包时要继续往下一个城市运输，否则就会出现传递错误的情况。当然，不排除有个别人私自截留快递包的行为——不管这种行为是否有意为之，都很可能导致系统bug的出现。

理解了拦截的概念后，再来分析上面的源码段就清晰多了。

Step1@dispatchTouchEvent。前面说过，DOWN是后续其他事件流的“领头羊”，被看成一个完整事件流程的起点。所以一旦收到ACTION_DOWN，程序就会清理以前的状态，即cancelAndClearTouchTargets和resetTouchState。

Step2@dispatchTouchEvent。变量intercepted代表是否要拦截事件。判断标准如下：

- Case 1. actionMasked == MotionEvent.ACTION_DOWN || mFirstTouchTarget != null

如果是DOWN事件，或者mFirstTouchTarget不为空，那么又分为两种子情况。

- Case 1.1 disallowIntercept为false

也就是说，此ViewGroup允许拦截，此时就可以进一步调用intercepted = onInterceptTouch Event(ev)来由后者判断是否要真正执行拦截了。这样做的目的是为扩展ViewGroup类提供便利——它们只需要重载这个函数就能改变ViewGroup的Intercept策略。

- Case 1.2 disallowIntercept为true

说明ViewGroup不允许拦截，这种情况下当然intercepted=false。

- Case 2. 如果这不是DOWN事件，而且在之前的判断中mFirstTouchTarget为空，那么intercepted为true，表示ViewGroup选择继续拦截事件。

在这一系列的判断中，ViewGroup始终优先考虑拦截的可能性。通常情况下，这一决定权会落在onInterceptTouchEvent中，因而在编写这个函数时要特别小心。

Step3@dispatchTouchEvent。如果intercepted为false，表明ViewGroup不希望拦截这一消息，因而它的子对象将有机会来处理它。源代码如下：

```
if (actionMasked == MotionEvent.ACTION_DOWN
        || (split && actionMasked == MotionEvent.ACTI
        || actionMasked == MotionEvent.ACTION_HOVER_M
    …
    final int childrenCount = mChildrenCount;//子对象个
    if (newTouchTarget == null &&childrenCount != 0)
        final float x = ev.getX(actionIndex);
        final float y = ev.getY(actionIndex);
        final View[] children = mChildren;
        …
        for (int i = childrenCount - 1; i >= 0; i--)
                                            //循环查找一个能处理
       final int childIndex = customOrder ?
                            getChildDrawingOrder(child
            final View child = children[childIndex];
            if (!canViewReceivePointerEvents(child)
                  || !isTransformedTouchPointInView(x
                continue;//不符合要求，跳过
            }
            //找到了此TouchEvent的归属child
            newTouchTarget = getTouchTarget(child);
            …
            if (dispatchTransformedTouchEvent(ev, fal
                …
                break;//确实完成了任务，可以结束循环了
            }
        }
    }
  …
}
```

这部分代码段的核心就是如何判断此Touch事件在ViewGroup众多子对象中的归属。换句话说，在这么多的子对象中，ViewGroup采取什么策略才是公平正确的。一个“下策”就是把事件挨个发送给每个子对象，然后由它们自己来决定是否要接受这个Touch Event。这有点像广播机制，缺点就是浪费时间，而且加重了View本身的任务——它需要有能力预先判断这一事件是否属于自身。

执行归属判断的是canViewReceivePointerEvents和isTransformedTouchPointInView。前者表示这个child是否能接收Pointer Events（包括Touch Event）；后者则是计算（x,y）这个点有没有“落在”此child的“管辖”范围内。这样做就相对公平了，秉承“谁的辖区谁负责”的观念，而且对于不符合要求的子对象可以直接continue跳过，从而节约了时间。

如果找到了事件的归属者，接下来就要将此事件投递给它了，实现函数是dispatchTransformed TouchEvent。这个函数将调用child的dispatchTouchEvent，分两种情况：如果这个子对象是View，可以参考上一小节的分析；否则就仍然是ViewGroup中的dispatchTouchEvent。如此循环往复，直到事件真正被处理。

当然，事件的归属者并不一定就是最终事件的处理者。打个比方，快递包上的地址写错了。于是虽然正确到达了指定的地点，但接收方不认账，而返回了false。此时包裹还需要继续流转，以寻求真正的处理者。

最后我们来小结一下。ViewGroup中的dispatchTouchEvent比View复杂很多，因为它不仅要考虑ViewGroup本身的处理，更重要的是要保证消息能在整棵View Tree中得到正确的传递。从这个角度出发，我们可以把它的处理过程分为以下几个方面来理解。

- 消息往下传递的时机

即什么情况下ViewGroup可以直接intercept此消息，而另外一些情况下则需要把消息继续传递给它管理下的子对象做进一步处理。大家应该已经想到了，起决定作用的就是onInterceptTouch Event。Android系统鼓励大家在继承ViewGroup时只重载onInterceptTouchEvent，而不是重载dispatchTouchEvent。因为后者可谓所有ViewGroup共性的提取，不应轻易改变；而前者才是体现每个ViewGroup对象“基因”差异

的地方。我们应该尽可能地复用已经成熟的代码，而不是什么事都“亲历亲为”，这样做并不符合软件开发的理念。

当onInterceptTouchEvent返回false时，说明当前的ViewGroup并没有截留这个事件，所以它需要继续往下传输，直到有人接收并处理它；同时，后续的事件还会源源不断地调用onInterceptTouchEvent进行判断。

而当onInterceptTouchEvent返回true时，说明当前的ViewGroup需要截留这个事件以供内部处理。此时意味着这个事件以及后续的事件直到ACTION_UP前都会直接投递到ViewGroup的onTouchEvent中，而不会往下传递。

处理逻辑如图11-35所示。

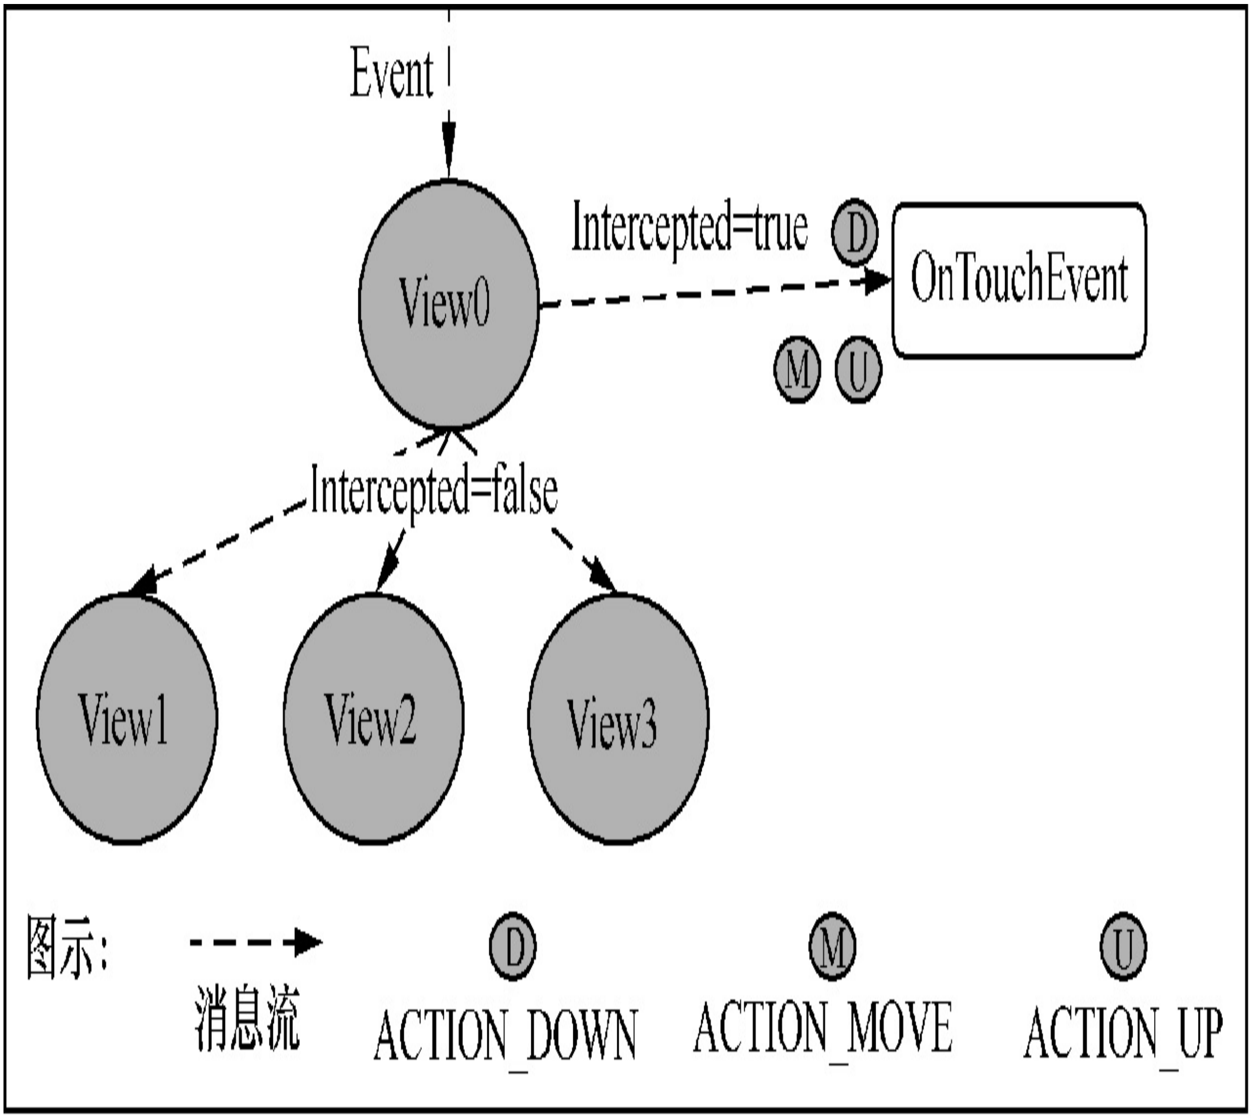

▲图11-35　ViewGroup中触摸消息流的传递简图

- ViewGroup自身对消息的处理

ViewGroup也是View对象，所以它同样有权对事件进行处理。具体的实现和前一小节的分析完全一致，读者可以结合起来阅读。

11.11 View动画

Android系统中至少提供了如下几种类型的动画。

- Property Animation

这是从Android 3.0起才导入的一种新的动画方式，也是官方推荐使用的做法。它将以某个对象，甚至是那些并不在屏幕上显示的对象的属性为动画契机。因而突破了View动画的传统限制，极大地扩展了原先动画的灵活性。

- View Animation

View Animation也是我们在开发过程中经常使用的一种方法。虽然它只提供了大小、旋转、透明度等基础属性的动画效果，但已经足够满足一般的开发需求。建议读者在选择具体的动画方式时，要根据实际的需求来选择，而不是越“高级”越好。

本小节的内容将以View Animation为分析重点。

- Drawable Animation

这是传统的动画实现方式之一，即通过连续放映图片来产生动画的效果。相对于上面两种，它的优点是可以实现任何动画而且效果出色；缺点也是明显的，即要花费一定的人力物力来完成动画所需的相关图片，而且应用程序的体积也会因此增大。

- Window Animation

这是系统内部实现的一种动画，目的在于加强窗口切换时的显示效果。我们在Window ManagerService中已经有详细介绍。

接下来我们以View Animation为例来分析View动画的实现原理。实际上，不管是什么类型的动画，其本质原理都是一样的。引用Wikipedia上对Animation的解释，即：

```
Animation is the rapid display of a sequence of images to create
```

也就是说，动画的本质是时间和图像的关系。比如一个滚动的小球，在0秒时显示的是位移为1m的图片；而到了1秒时显示的是位移为2m的图片；3秒时显示的是位移为3m的图片等。在这一过程中，所有图片都是静止的，它们通过在不同的时间内有序地显示出来从而造成了“动起来”的感觉。根据视觉原理，人体对于一幅图的“存储时间”是0.34秒，因而只要以特定的速率来切换图片（根据人们的反复测试经验，电影一般选取24帧/秒，电视则是25帧/秒），人眼就会感觉整个画面是流畅的，没有卡顿现象。

从上面的分析可以得出实现View Animation的重点，如下所述。

1．从开发人员的角度来讲

对于开发人员而言，他们所关心的是如何快速地将所需的动画效果告知系统，然后通过调用尽量少的函数就可以开始执行和控制动画。具体来说，在Android系统中实施一个View动画需要以下几个步骤。

- 首先需要填写xml动画资源文件。

和其他类别的资源一样，我们也可以通过xml来描述一个View动画资源。比如新建一个example_anim.xml到res/anim/目录下，然后根据以下格式范例来生成一个动画效果：

```
<?xml version="1.0" encoding="utf-8"?>
<set xmlns:android="http://schemas.android.com/apk/res/android"
    android:interpolator="@[package:]anim/interpolator_resource"
    android:shareInterpolator=["true" | "false"] >
<alpha
        android:fromAlpha="float"
        android:toAlpha="float" />
<scale
        android:fromXScale="float"
        android:toXScale="float"
        android:fromYScale="float"
        android:toYScale="float"
        android:pivotX="float"
        android:pivotY="float" />
<translate
        android:fromXDelta="float"
        android:toXDelta="float"
        android:fromYDelta="float"
        android:toYDelta="float" />
```

```
<rotate
        android:fromDegrees="float"
        android:toDegrees="float"
        android:pivotX="float"
        android:pivotY="float" />
<set>
        ...
</set>
</set>
```

一个描述动画资源的xml文件必须以<alpha>，<scale>，<translate>，<rotate>或者<set>为根节点，其中最后的<set>表示前面四种类别的组合，它在源码中的实现类是AnimationSet。这5个元素的属性和释义如表11-9所示。

表11-9　动画资源各属性释义

Element	Properties	Description
<set>	android:interpolator	Animation要采用的Interpolator，下面我们会讲到
	android:shareInterpolator	是否要将这个Interpolator在所有子元素中共享
<alpha>	android:fromAlpha	表示动画起始时的alpha值。取值范围0.0（透明）～1.0（不透明），float类型
	android:toAlpha	表示动画结束时的alpha值。取值范围0.0（透明）～1.0（不透明），float类型
<scale>	android:fromXScale	表示动画起始时，X方向的缩放倍数，float类型，1.0为没有变化
	android:toXScale	表示动画结束时，X方向的缩放倍数，float类型，1.0为没有变化
	android:fromYScale	表示动画起始时，Y方向的缩放倍数，float类型，1.0为没有变化

	android:toYScale	表示动画结束时，Y方向的缩放倍数，float类型，1.0为没有变化
	android:pivotX	缩放中心点的X坐标
	android:pivotY	缩放中心点的Y坐标
<translate>	android:fromXDelta	移动点的X坐标起始值，<translate>既可以是绝对数值，也可以是百分比（%p表示相对于父对象，%则是相对于自身），下面几个属性也是类似的
	android:toXDelta	移动点的X坐标结束值
	android:fromYDelta	移动点的Y坐标起始值
	android:toYDelta	移动点的Y坐标结束值
<rotate>	android:fromDegrees	旋转度数起始值，float类型
	android:toDegrees	旋转度数结束值，float类型
	android:pivotX	旋转中心点的X坐标，float或者percentage（相对于上边缘）类型
	android:pivotY	旋转中心点的Y坐标，类型同上

除了上述属性外，每个元素还可以指定android:duration，也就是动画执行的时间长度。这个值越小，则动画从起点到终点所用的时间就越短。另外，android:startOffset则指明动画开始前的延时时间——当调用start来执行动画时，有时候我们希望某些动画效果稍慢于其他一些动画，这时就可以采用这个属性。默认情况下，所有动画一开始就执行了。

可见，上面的属性多数只是描述了起始和终点时动画的状态，而没有给出中间过程的变化，完成这一任务的就是Interpolator。简单来讲，它给出了动画的变化速率，种类非常多，如匀速运动的Interpolator和抛物线运动的Interpolator等。在实现上，它们都继承自Interpolator。原生的Android系统本身已经提供了诸如

AccelerateDecelerateInterpolator，AccelerateInterpolator，Anticipate Interpolator，LinearInterpolator等一系列常用的Interpolator。开发者可以通过“@android:anim/[Interpolator_Name]”来引用它们。比如：

```
<set android:interpolator="@android:anim/ LinearInterpolator">
    ...
</set>
```

另外，我们还可以通过上面属性表格中的android:interpolator来指定一个自定义的Interpolator实现类。具体例子可以参考官方文档说明。

对于开发人员来说，他们通过xml描述的动画资源实际上给出了以下信息：

- 有几个动画（rotate，scale，translate，alpha）需要执行；
- 每个动画的起始和最终效果；
- 每个动画的起始时间和延续时长（duration）；
- 完成每个动画的Interpolator。

在应用程序中使用一个xml动画资源时，通常可以这么做：

```
ImageView image = (ImageView) findViewById(R.id.image);
Animation  exampleAnim = AnimationUtils.loadAnimation(this, R.ani
image.startAnimation(exampleAnim);
```

余下的工作就由系统自动完成了。

2．从系统实现的角度来讲

当应用程序通过loadAnimation加载一个xml动画资源文件时，返回的是一个Animation对象。不过大部分情况下，它其实是AnimationSet。这个类继承自Animation，有点类似于View与ViewGroup的关系。每一个Animation都属于上述4种动画（scale，rotate等）的其中一种，AnimationSet则是它们的集合。在AnimationSet内部，有一个mAnimations的ArrayList变量来记录它包含的所有动画，如图11-36所示。

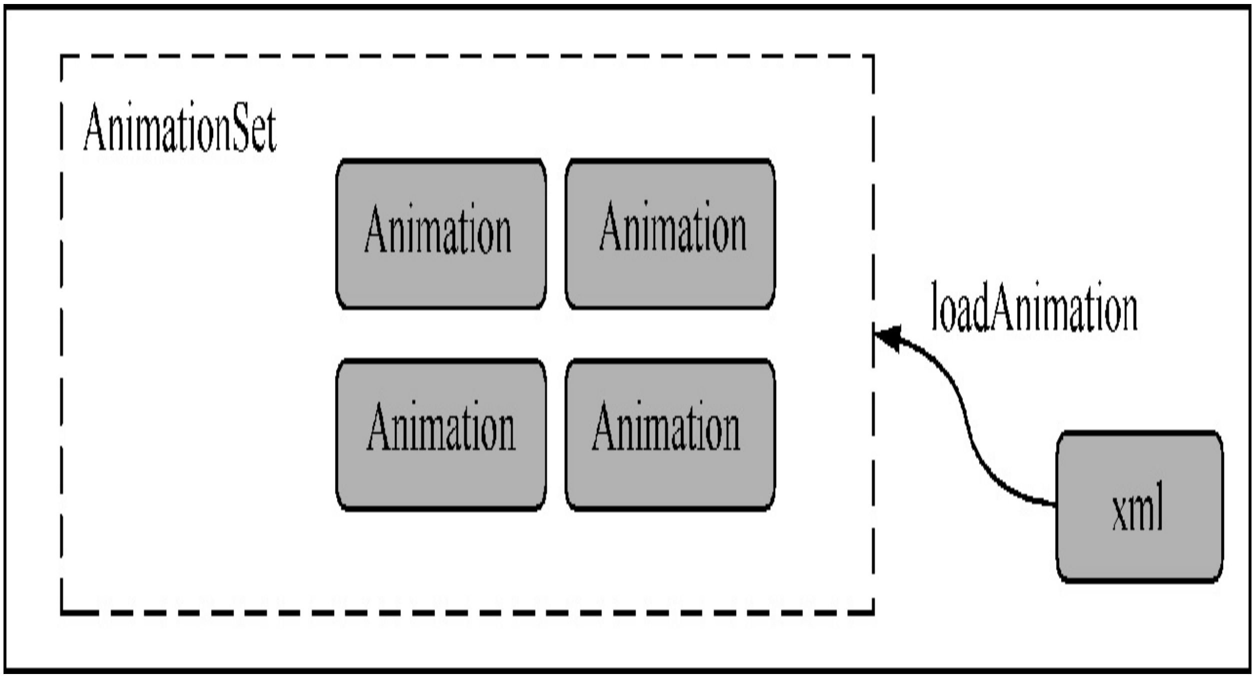

▲图11-36　AnimationSet和Animation的关系图

下面为了简化分析过程，我们还是以Animation来表示一个动画主体。

它们的继承关系如图11-37所示。

Animation类的最终目的是提供getTransformation接口实现，这个函数将返回当前时间点的Transformation给View进行相应处理。熟悉图形变换的开发人员应该能想到，一个View的位移、旋转、缩放是可以用matrix来表达的，那么为什么还要定义一个Transformation呢？没错，因为还有Alpha这个属性是matrix所不能表示的。我们可以看看Transformation内部的全局变量：

```
/*frameworks/base/core/java/android/view/animation/Transformation
public class Transformation {
    protected Matrix mMatrix;
    protected float mAlpha;
    …
```

从Animation的角度来看，它需要计算出任何时间点的Transformation值。如果只是匀速运动的动画，实现相对简单。而如果是非匀速运动呢？这些烦琐的计算实际上是一个个数学模型，我们统一

用Interpolator来实现。

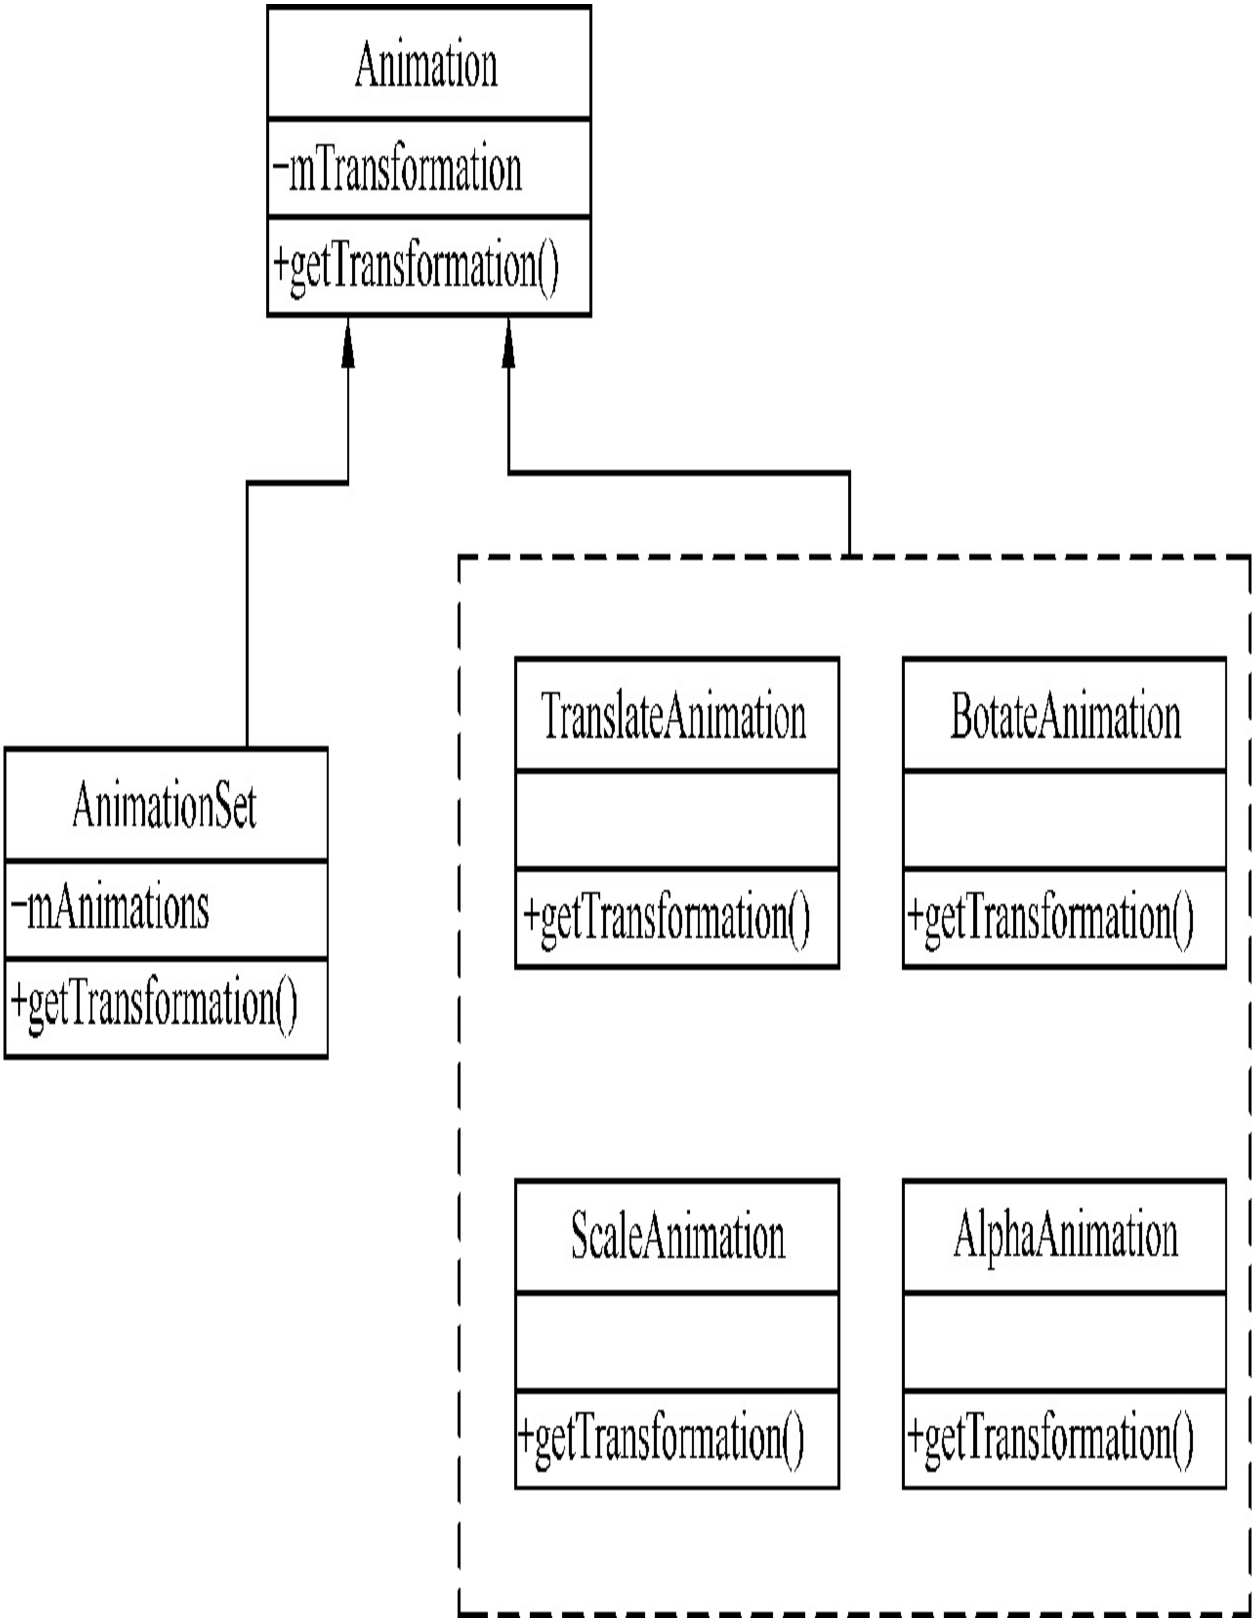

▲图11-37 Animation继承关系图

下面举两个动画实例来进一步理解Interpolator。

例1：AlphaAnimation，初始条件如下。

- Alpha起始值：0.0，终值：1.0。
- 动画时长：2s，起始时间：1s，即动画起止时间是1～3s。
- 采用LinearInterpolator。

Interpolator本身只是一个接口类，所有继承它的子类都要实现getInterpolation(float input)。其中input是唯一的入参，表示当前时间点在整个动画时长中对应的位置（以0.0-1.0表示，也就是实现了归一化）。在这个例子中，如果当前时间是2s，那么input=(当前时间-起始时间)/(动画时长)=(2-1)/2=0.5。由于是匀速运动，速度在任何时间点都是恒定不变的，所以getInterpolation的返回值即input本身：

```
public class LinearInterpolator implements Interpolator {
    …
    public float getInterpolation(float input) {
        return input;
    }
```

得到这个返回值后，Animation可以计算出Transformation：

```
     /*frameworks/base/core/java/android/view/animation/AlphaAnim
     protected void applyTransformation(float interpolatedTime, T
          final float alpha = mFromAlpha;
          t.setAlpha(alpha + ((mToAlpha - alpha) * interpolatedTi
    }
```

可见在LinearInterpolator的情况下，动画的计算过程比较简单明了。

例2：采用AccelerateInterpolator，其他条件则和例1相同。

现在情况有了变化，即速度v不再是恒定不变的。我们假设加速度不变，恒定为v=t，如图11-38所示。

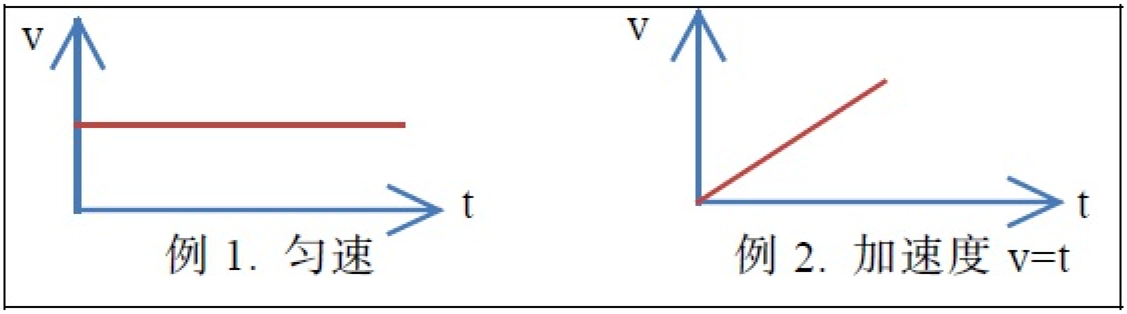

▲图11-38 两个例子中的速度对比

因为s=vt=t*t，意味着随着时间的增加，s值的增长会越来越快：

```
/*frameworks/base/core/java/android/view/animation/AccelerateInte
public float getInterpolation(float input) {
        if (mFactor == 1.0f) {
            return input * input;
        } else {
            return (float)Math.pow(input, mDoubleFactor);
        }
    }
```

从上面两个例子的分析中，我们可以得出两个结论。

- Interpolator得到的是当前时间点，动画变换值在整个变换中的位置。
- getInterpolation的返回值范围是0.0～1.0，且任何Interpolator在input为1时，输出一定为1.0。

到目前为止，我们理解的动画实现可以抽象成图11-39。

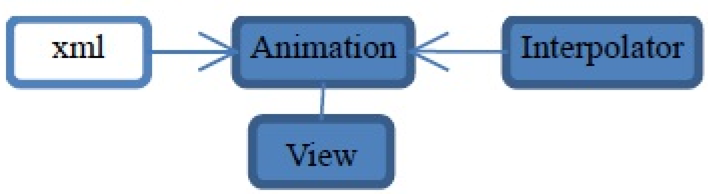

▲图11-39 动画实现简图

Animation通过解析xml文件得到用户希望产生的动画效果，并进行

初始化。然后在Interpolator的约束下不断地与View进行交互（Transformation），从而产生动画过程。“不断地”表明必须要有一个机制来促使这一流程源源不断地运转，直到动画结束。一般情况下，我们会想到启动一个timer来达到这种目的。基于这点考虑，上面的简图还应该包括如下几个元素。

- 时间器

时间器从动画一开始就要启动，直到动画结束；同时，它也负责对动画刷新频率的管理。换句话说，每隔多长时间发出一次刷新信号对于画面的连贯性有不小的影响。

- 效果计算器

当时间器发出信号后，我们需要知道在当前的时间点，应该“描绘”一幅怎样的“画面”。比如滚动中的小球，以1m/s的速度移动时，那么2秒后的“画面”应该显示它已经移动了2米。当然实际的动画计算肯定比这个例子复杂，如还要综合考虑旋转、大小等的变化。

- 效果计算器输出的内容如何体现到UI中

前面的时间器、效果计算器，在Android系统中都是由Animation类来完成的。那么当Animation计算出在某个时间点应该产生什么图像时，如何把这些结果告知系统呢？这就涉及Animation与View的接口了，如图11-40所示。

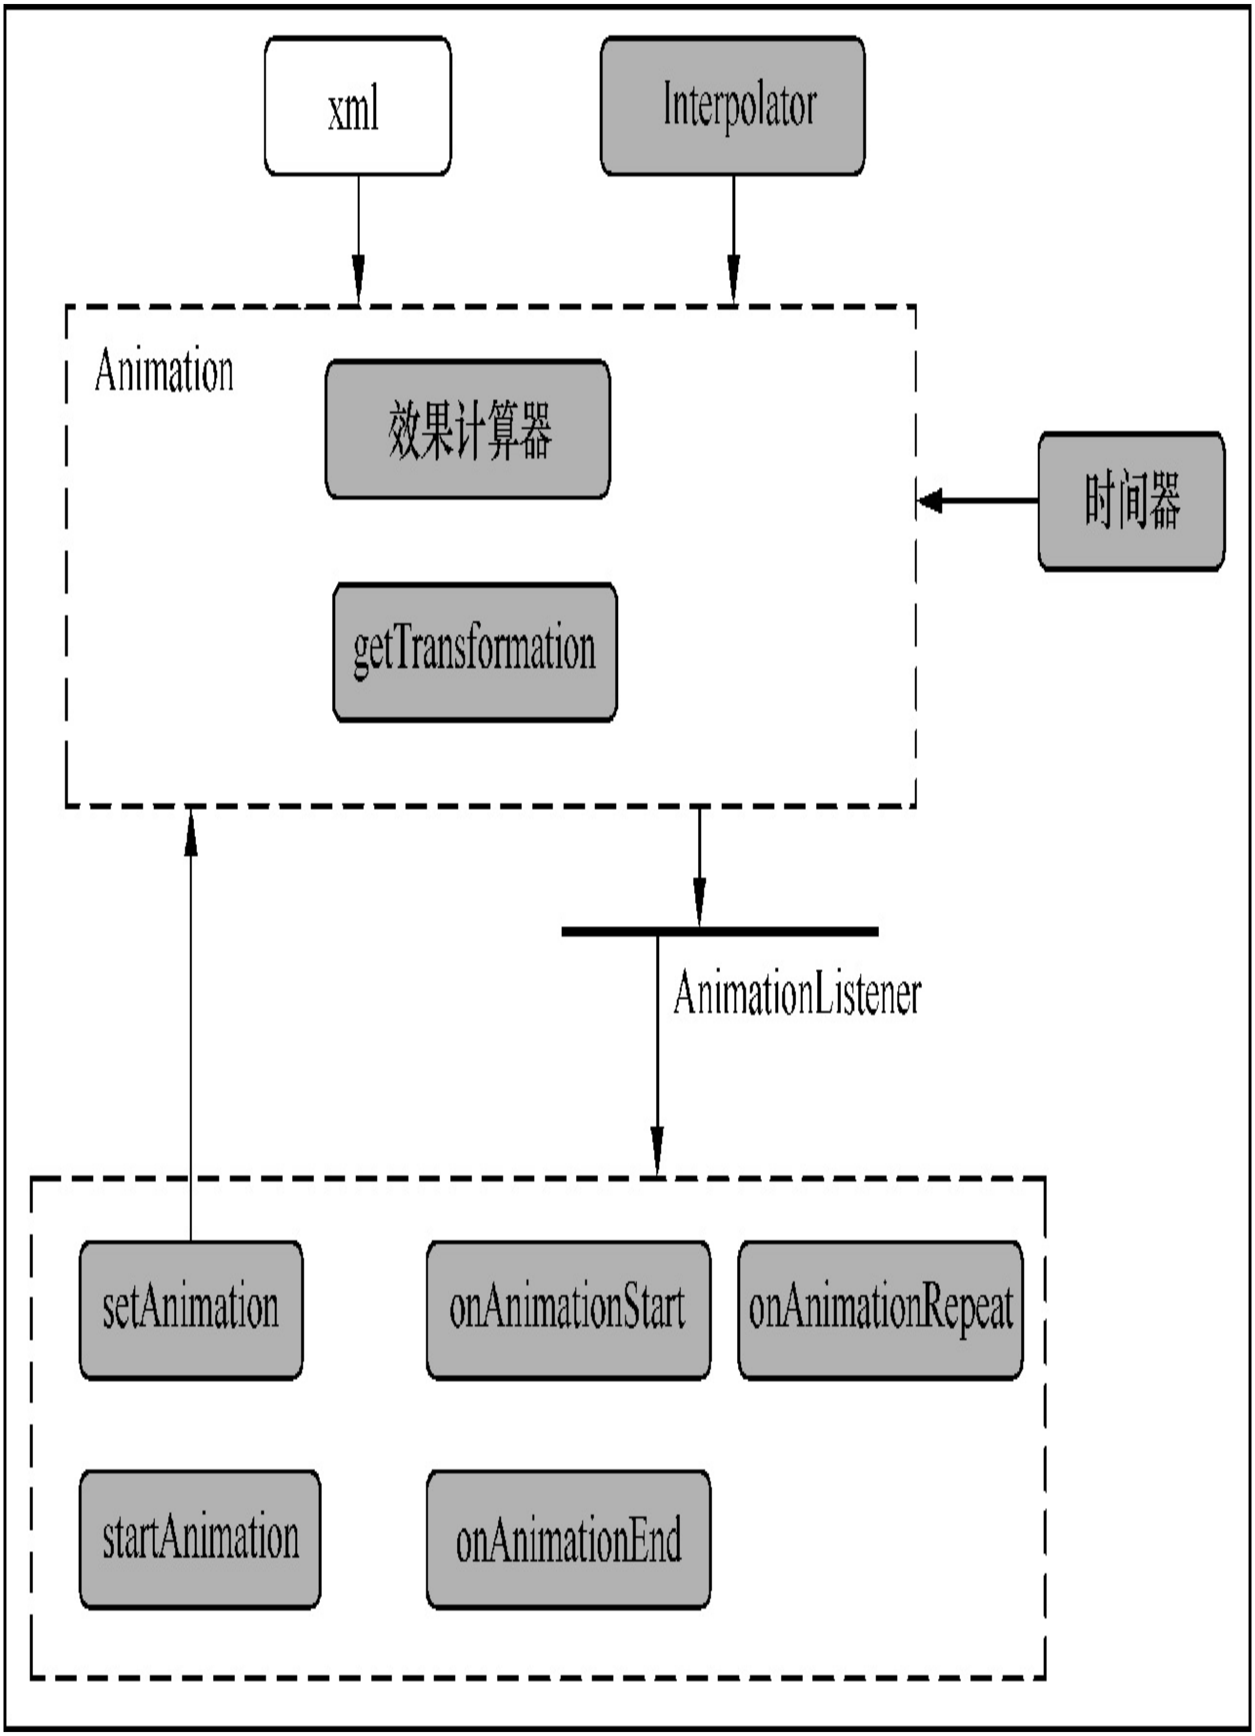
xml
Interpolator
Animation
效果计算器
getTransformation
时间器
AnimationListener
setAnimation
onAnimationStart
onAnimationRepeat
startAnimation
onAnimationEnd

▲图11-40　View与Animation间的接口

图11-40的确是一个有效的Animation实现方案。不过在Android中，我们却没有从Animation类中发现Timer的踪迹，而且AnimationListener也没有提供Transformation的回调。那么，View是如何使整个动画流程“动”起来的呢？答案就是View会主动调用Animation进行查询，即getTransformation。换句话说，何时去获取当前的“动画状态”是View的责任与权利，和Animation并没有关系。如此一来，问题就转换成：View在什么情况下会去“不断地”调用getTransformation呢？

前面代码中调用startAnimation后，其内部最后会调用invalidate：

```
public void startAnimation(Animation animation) {
    …
    invalidate(true);
     …
```

这样就发起了一次重绘请求，并在后续过程中处理与Animation相关的操作。详细过程可参考本章前面小节的介绍，此处不再赘述。

11.12 UiAutomator

相信大家对UiAutomator并不陌生，这个Android官方提供的自动化测试框架具有非常强大的功能，是我们测试应用程序的首选工具之一。与Instrumentation不同的是，UiAutomator并不与被测程序运行于同一进程中，因而它可以实现跨进程的测试。比如你可以利用UiAutomator获取到当前设备中正在显示的页面中的元素，然后对它们进行各种操作；也可以要求设备返回桌面，或者执行Back命令。

UiAutomator的强大功能是如何实现的呢？

事实上，UiAutomator只是一个“壳”，它真正倚赖的法宝是如下3个模块：

- UiAutomation

UiAutomation并非Google的专利，业界其他公司（譬如Apple）亦有与之同名的测试框架。从出现时间上来推测，Android中的UiAutomation很可能是Google“仿照”出来的。当然，站在巨人的肩膀上本身并非坏事，更何况是“造福众人”的开源项目。

- Accessibility Service

乍看这个Service，可能不少人会觉得奇怪，它们之间怎么会有关联——UiAutomator和Accessibility Service似乎“八杆子都打不着”？但再细想一下，就不难发现它们的任务是有共同点的。Accessibility Service旨在帮助那些有某些方面缺陷的人士可以像正常人一样使用Android设备，譬如Accessibility Service可以通过语音告知盲人用户当前的设备界面，以便后者在知悉了这些信息后可以再利用语音命令来发出界面的控制命令。在这一过程中，Accessibility Service获取界面元素以及它控制界面的能力又恰恰是UiAutomator所需要的。因而二者可以说是“一拍即合”。

- ViewRoot

Accessibility Service绝对不是“神”，它的权利最终是ViewRoot赋予的。这也是为什么我们选择将UiAutomator的原理在本章

节进行讲述的原因之一。

如果大家对于UiAutomator测试用例的书写，以及它的基本使用方法有不清楚的地方，建议可以先到Android官网查询相关资料，限于篇幅我们这里不做详细介绍。接下来我们的重点是阐述UiAutomator的核心实现原理。

首先，从“adb shell uiautomator runtest…”这种命令格式中不难看出，UiAutomator会是/system/bin下的一个可执行程序。而且这个可执行程序只是一个shell脚本文件，源码路径在/frameworks/testing/ uiautomator/cmds/uiautomator下。值得一提的是，Android系统中类似的做法还有不少，比如pm、am等。

程序UiAutomator支持的几个主要命令包括runtest、dump和events等。其中runtest用于执行开发者提供的UiAutomator测试用例，dump则是sdk工具包中uiautomatorviewer的功能承载者。最终，UiAutomator会调用如下的语句来执行真正的操作：

```
exec app_process ${base}/bin com.android.commands.uiautomator.Lau
```

app_process同样是/system/bin目录下的一个可执行文件，它同时也是Zygote的承载体，其本质上就是帮助用户快速建立一个Android虚拟机，以便Java程序可以顺利运行。

UiAutomator Launcher会根据子命令的不同，分别调用相应的Java类进行处理。例如runtest命令将在RunTestCommand.java中被解析，具体而言它会先创建一个UiAutomatorTestRunner，然后开始执行测试用例：

```
/*frameworks/testing/uiautomator/library/testrunner-src/com/andro
 protected void start() {
        …
        UiAutomationShellWrapper automationWrapper = new UiAutoma
        automationWrapper.connect();
```

上述的start函数是testrunner执行测试任务的核心之一。不过我们摒弃掉了其他琐碎部分，只把焦点放在了如何与UiAutomation建立连接上。UiAutomationShellWrapper即是testrunner与UiAutomation之间的桥梁，如下所示：

```
/*frameworks/testing/uiautomator/library/testrunner-src/com/andro
public void connect() {…
        mUiAutomation = new UiAutomation(mHandlerThread.getLooper
                new UiAutomationConnection());
        mUiAutomation.connect();
}
```

可以看到UiAutomation出场了，同样也是调用了connect函数——而这个connect又最终调用了UiAutomationConnection中的同名函数。如下所示：

```
/*frameworks/base/core/java/android/app/UiAutomationConnection.ja
public void connect(IAccessibilityServiceClient client) {
       …
            registerUiTestAutomationServiceLocked(client);
            storeRotationStateLocked();
        }
    }
```

简单来讲，函数registerUiTestAutomationServiceLocked将在UiAutomation内部建立一个IAccessibilityServiceClient和AccessibilityService之间的连接。为了让大家更好地理解Accessibility书馆Service的业务流程，我们接下来选取“获取当前界面的UI元素”这一场景来分析其中的实现原理。

我们知道，UiAutomator提供了如表11-10所示的API类来帮助开发者完成测试用例的编写。

表11-10　AP工类

Classes	Description
com.android.uiautomator.core.UiCollection	用户界面元素的集合
com.android.uiautomator.core.UiDevice	提供了访问设备信息的接口，以及模拟用户操作（譬如单击Home、Menu键等）

	的方法
com.android.uiautomator.core.UiObject	代表一个UI元素
com.android.uiautomator.core.UiScrollable	辅助在一个可滚动的UI窗口中查找元素
com.android.uiautomator.core.UiSelector	用于描述需要被测试的目标

其中UiSelector可以通过文本值、class name以及其他多种属性来匹配当前界面中与之对应的UiObject。以UI元素的index属性为例，我们来看一下它是如何查找到正确的目标对象的：

```
/*frameworks/testing/uiautomator/library/core-src/com/android/uia
UiSelector.java*/
public UiSelector index(final int index) {
        return buildSelector(SELECTOR_INDEX, index);
}
```

可见上述函数直接调用了buildSelector。其中SELECTOR_INDEX代表的是UI元素的属性，其他的还有SELECTOR_CLASS、SELECTOR_ID等。

```
/* frameworks/testing/uiautomator/library/core-src/com/android/ui
UiSelector.java */
private UiSelector buildSelector(int selectorId, Object selectorV
        UiSelector selector = new UiSelector(this);
        if (selectorId == SELECTOR_CHILD || selectorId == SELECTO
            selector.getLastSubSelector().mSelectorAttributes.put
        else
            selector.mSelectorAttributes.put(selectorId, selector
        return selector;
    }
```

到目前为止，对于UiSelector的操作都属于UiAutomator“本地”，换句话说它并未与Accessibility Service发生任何实质关联，更多地只是在内部“做了个记号，以备后用”。这样一来，查找目标对

象的工作自然而然地就落在了UiObject上。以对一个目标控件执行Click操作为例，对应的代码如下：

```
/* frameworks/testing/uiautomator/library/core-src/com/android/ui
UiObject.java*/
public boolean click() throws UiObjectNotFoundException {
        Tracer.trace();
        AccessibilityNodeInfo node = findAccessibilityNodeInfo(mC
        …
    }
```

可以看到UiObject在每执行一个操作前，都会利用findAccessibilityNodeInfo来查找匹配的对象。后面这个函数最终又会利用UiDevice.getInstance().getAutomatorBridge().getQueryController
findAccessibilityNodeInfo(getSelector())来完成它的任务。UiDevice中的AutomatorBride是由UiAutomatorTestRunner在Start时通过initialize初始化而来的，对应的是一个ShellUiAutomator
Bridge。我们省略其中的细枝末节，直接分析QueryController中的对应实现：

```
/* frameworks/testing/uiautomator/library/core-src/com/android/ui
Controller.java*/
 protected AccessibilityNodeInfo findAccessibilityNodeInfo(UiSele
            boolean isCounting) { …
        synchronized (mLock) {
            AccessibilityNodeInfo rootNode = getRootNode();
            …
            UiSelector uiSelector = new UiSelector(selector);
            return translateCompoundSelector(uiSelector, rootNode
        }
    }
```

上述这个函数的核心重点是getRootNode，它用于获取当前活跃窗口的最顶层元素，而UiSelector所指定的具体元素（如我们这个场景中通过index属性来查找的目标对象）则需要在此基础上运算得到。函数getRootNode的实现如下：

```
/* frameworks/testing/uiautomator/library/core-src/com/android/ui
Controller.java*/
protected AccessibilityNodeInfo getRootNode() {
        final int maxRetry = 4;
        final long waitInterval = 250;
```

```
        AccessibilityNodeInfo rootNode = null;
        for(int x = 0; x < maxRetry; x++) {
            rootNode = mUiAutomatorBridge.getRootInActiveWindow()
            if (rootNode != null) {
                return rootNode;
            }
            …
        }
        return rootNode;
}
```

可以看到，获取活跃窗口的顶层元素并不是能一次性成功的，因而我们设置了4次重试机会。变量mUiAutomatorBridge是对于UiAutomation的桥接，后者又调用了AccessibilityInteractionClient提供的getRootInActiveWindow(connectionId)来最终完成与AccessibilityManagerService的通信。

这个过程中所涉及的类比较多，容易搞混，我们特别以如下UML示例图来帮助大家理解，如图11-41所示。

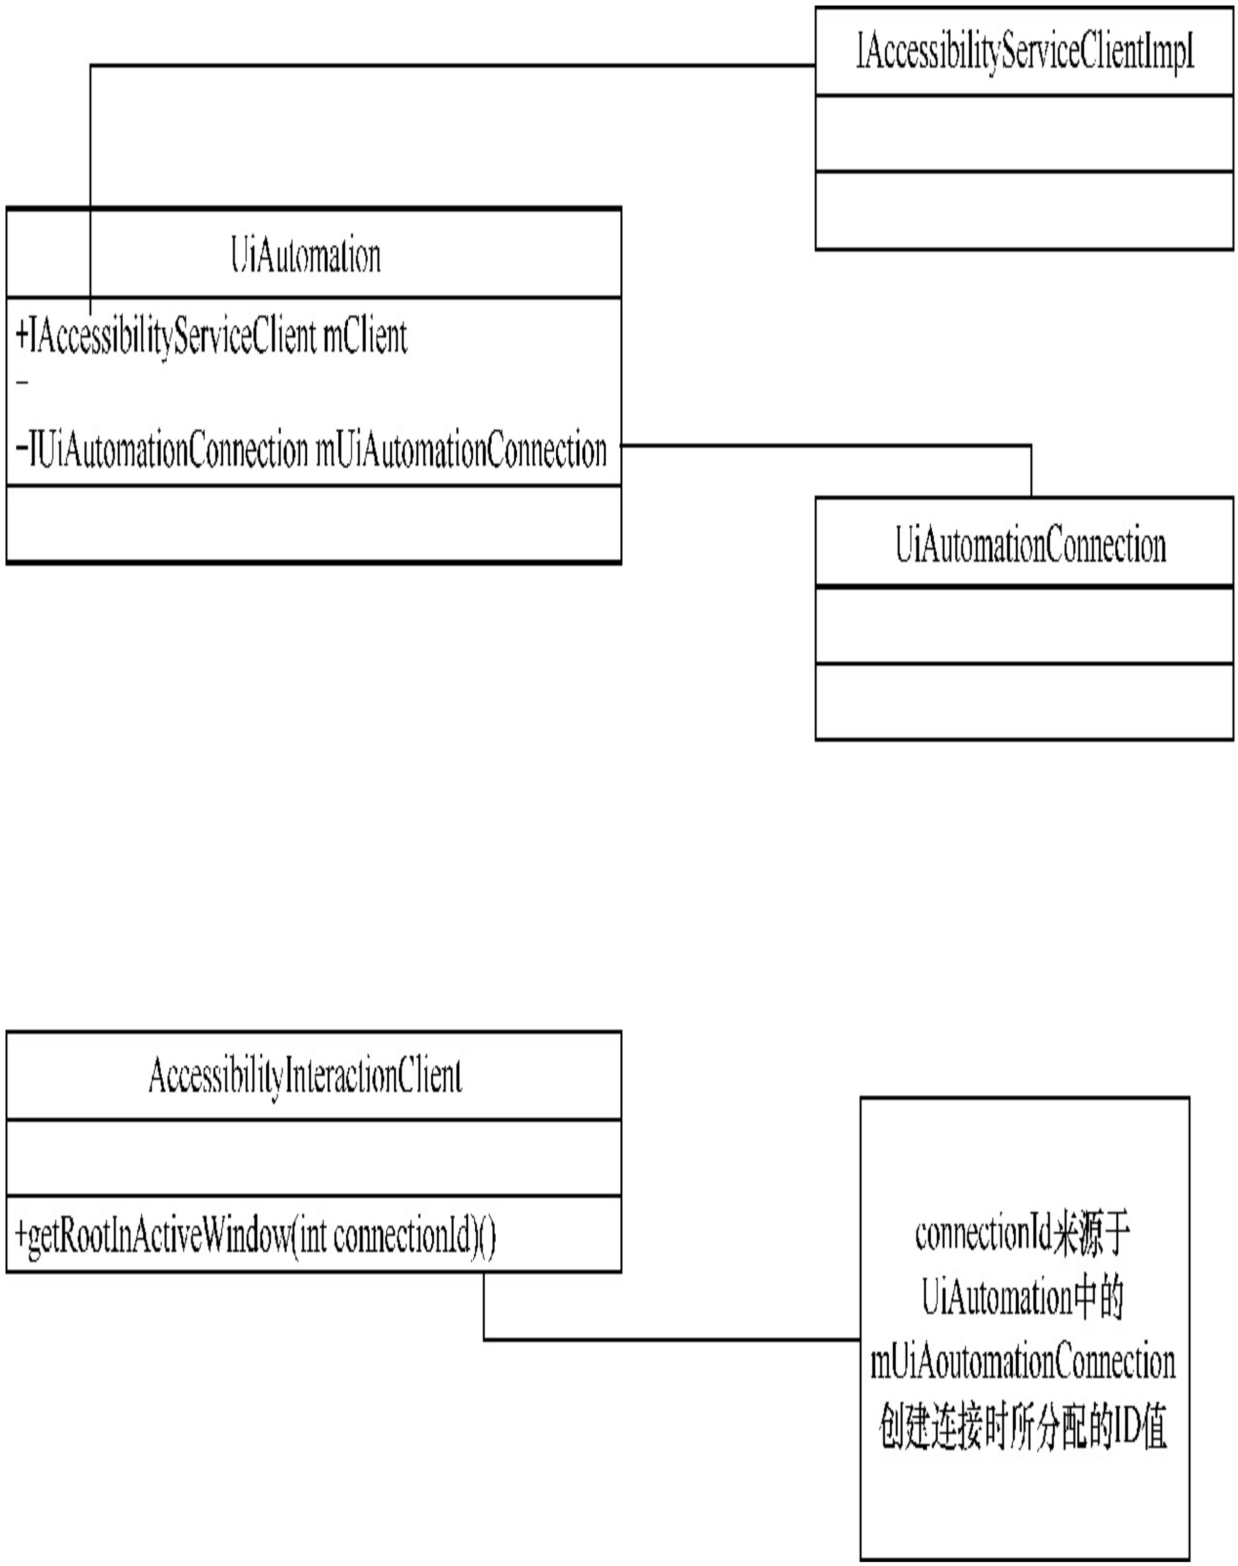

▲图11-41　UML示例图

所以一个UiAutomator测试用例的大致执行流程是：

UiObject/UiDevice/UiSelector->QueryController->UiAutomatorBridge->UiAutomation->…->AccessibilityManagerService->…->ViewRoot/WindowManagerService/InputManager。

因为AccessibilityManagerService是一个“中介”，其所涉及的业务范围是比较广泛的。比如为了获取当前系统中的所有可见窗口（getWindows接口），它需要与WindowManagerService有交流；而为了控制输入法操作，它也应该和InputManager有关联；同样为了获得一个窗口中的UI控件，它还必须与ViewRoot建立合作关系等。

以getRootInActiveWindow为例，其最终会调用ViewRootImpl中的findAccessibility NodeInfoByAccessibilityId，而后经过多次中转传递后再由AccessibilityInteractionController进行处理：

```
/*frameworks/base/core/java/android/view/AccessibilityInteraction
private void findAccessibilityNodeInfoByAccessibilityIdUiThread(M
        List<AccessibilityNodeInfo> infos = mTempAccessibilityNod
        infos.clear();
        try {
            if (mViewRootImpl.mView == null || mViewRootImpl.mAtt
                return;
            }
            mViewRootImpl.mAttachInfo.mAccessibilityFetchFlags =
            View root = null;
            if (accessibilityViewId == AccessibilityNodeInfo.UNDE
                root = mViewRootImpl.mView;
            } else {
                root = findViewByAccessibilityId(accessibilityVie
            }
            if (root != null && isShown(root)) {
                mPrefetcher.prefetchAccessibilityNodeInfos(root,
            }
        } finally {
            try {…
                adjustIsVisibleToUserIfNeeded(infos, interactiveR
                callback.setFindAccessibilityNodeInfosResult(info
                infos.clear();
            } catch (RemoteException re) {
                /* ignore - the other side will time out */
            }
        }
    }
```

假如当前ViewRoot中的顶层元素（即mView）为空，那么我们就可以直接返回了。否则再根据用户是否指定了AccessibilityViewId来决定下一步操作——如若没有特别说明，那么mView就是结果值了，不然还得调用findViewByAccessibilityId来做进一步查找。最后，我们将结果通过IAccessibilityInteractionConnectionCallback这个事先注册的回调接口来传回给用户。

值得一提的是，AccessibilityService一方面给特定用户带来了不小的便利，另一方面也可能会被用来完成一些“意料之外”的事情。比如迅速走红的“抢红包”神器实际上就是利用了辅助服务来帮助用户自动打开红包的。“水可载舟，亦可覆舟”，事物通常具有两面性，需要大家自行甄别权衡。

第12章 “问渠哪得清如许，为有源头活水来”——InputManagerService与输入事件

在大多数现代操作系统中，“事件”就是它们的“活水源头”。正是在“事件和消息”的不断产生、流转和处理中，整个软件系统才能“动”起来。

Android系统有一套从底层Linux内核到上层应用程序完整的消息产生、投递及处理机制——这同时也是外界与Android设备交互的基础。对于系统层的开发人员而言，他们经常要根据具体的硬件配置来扩展、修改和完善消息处理机制，因而深入理解其中的实现原理就显得异常重要。

同样，我们也希望应用开发工程师能熟练掌握Android消息处理框架。Android系统发展到今天，已经在手持设备之外的很多领域得到了广泛的应用。而不同的产品领域通常意味着环境与需求的差异。应用工程师只有在理解内部原理的基础上，才可能在多样的需求中立于不败之地，也才能为用户提供最佳的体验效果。

因此，本章的内容不论对哪一层面的开发人员来说，都具有一定的实用价值。另外，建议读者把本章与上一章节介绍的“View中的消息传递”结合起来阅读理解。

12.1　事件的分类

首先应该明白一个问题——什么是“事件”？

从广义上来说，事件的发生源分为“软件”与“硬件”两类，这里侧重于对后者的讨论。也就是说，它们是由真实物理硬件产生的消息，表明设备使用者的某种“意愿”。例如用户点击了触摸屏，而相应位置上是音乐播放器的“暂停”键，那么说明他希望暂停当前的音乐播放。如果从硬件设备角度来为Android系统中的事件分类，最重要的几种如下。

- 按键事件（KeyEvent）

由物理按键产生的事件。对于嵌入式设备，通常不会配备太多物理按键。比如手机一般只有Home、Back、Menu、Volume Up、Volume Down和Camera等常用功能键。

- 触摸事件（TouchEvent）

在触摸屏上点击、拖动，以及由它们的组合所产生的各种事件。这是Android系统中使用最广泛也是相对复杂的一种事件类型。根据Android项目经验，应用开发人员大部分的事件处理工作都和TouchEvent有关。

- 鼠标事件（MouseEvent）

鼠标操作引起的事件，在嵌入式设备中并不常用。

- 轨迹球事件（TrackBallEvent）

轨迹球基本已经被淘汰了，因而我们在本章中不做过多介绍。

本章接下来将重点分析两种事件类型，即KeyEvent和TouchEvent。

读者可以先思考一下：如果让我们来为这两种事件设计处理函数，应该怎么做呢？

按键事件：

按键有几种状态？没错，理论上只有两个——要么按下，要么松开，即对应于KeyDown和KeyUp。不过实际上却没那么简单，为什么呢？因为还有其他一些因素也是要考虑的，如长按、短按，或者按键组合（多个按键）的情况。比如我们在Windows操作系统中同时按Ctrl+Alt+Del组合键可以调出任务管理器，Android系统也同样支持这些操作。

所以总结起来，影响一个按键事件的因素包括：

- 按键的状态（按下，松开）；
- 状态持续的长短；
- 按键数量。

……

由此可以得出处理按键事件的几个基础接口，如下所示。

```
OnKeyDown();
onKeyUp();
onKeyLongPress();
onKeyMultiple();
```

触摸事件：

触摸事件比上述的按键事件要复杂一些。从用户的角度来看，正常的“触摸屏”设备既支持点击，也同时能“感应”滑动事件（MOVE）——这可以说是它和按键事件最大的区别。

比如iPhone手机经典的滑动解锁界面（见图12-1），它的操作分解开来只有3步：

▲图12-1　iPhone的经典解锁样式

- 按住滑块;
- 移动滑块;
- 松开滑块。

以上动作将产生3种触摸事件，即：

- 触摸点按下（TOUCH_DOWN）；
- 触摸点移动（TOUCH_MOVE）；
- 触摸点释放（TOUCH_UP）。

值得一提的是，由MOVE事件还可以派生出其他的事件，如fling。应用程序为了模拟真实的世界，就必须遵循一定的物理现象。举个例子，我们在地面上拖动一辆小车，放手后小车并不会马上停止，而是会继续向前再前进一段时间。应用到上面的解锁场景，就是当用户的手势已经释放后（TOUCH_UP），滑块本身也不会马上停止，而是转化为fling事件继续执行一小段时间。这些细节是我们提供良好用户体验的一个基础。

触摸事件相关的因素包括：

- 触摸点状态（按下，松开）；
- 触摸点移动（移动的距离大小、速度等）；
- 触摸点的数量（需要“触摸屏”设备的支持，并不是所有设备都可以多点操作）；
- 时间因素（长按、短按等）。

由此可以得出处理触摸事件的几个基础接口，如下所示：

```
onTouchDown();
onTouchUp();
onTouchMove();
onTouchLongPress();
onTouchMultiple();
……
```

有了上述的理解，再来分析Android系统中的实现就容易多了。

针对所有事件的共性，我们需要提取一个统一的抽象接口，这就是

InputEvent。从它的名称可以看出，Event属于I/O设备中的Input部分。

InputEvent下有两个子类，KeyEvent和MotionEvent。按键KeyEvent很容易理解，用于表达按键事件；而MotionEvent则是将所有能产生Movement的事件源进行统一管理，如Trackball、Finger、Mouse等。来看看它们的关系，如图12-2所示。

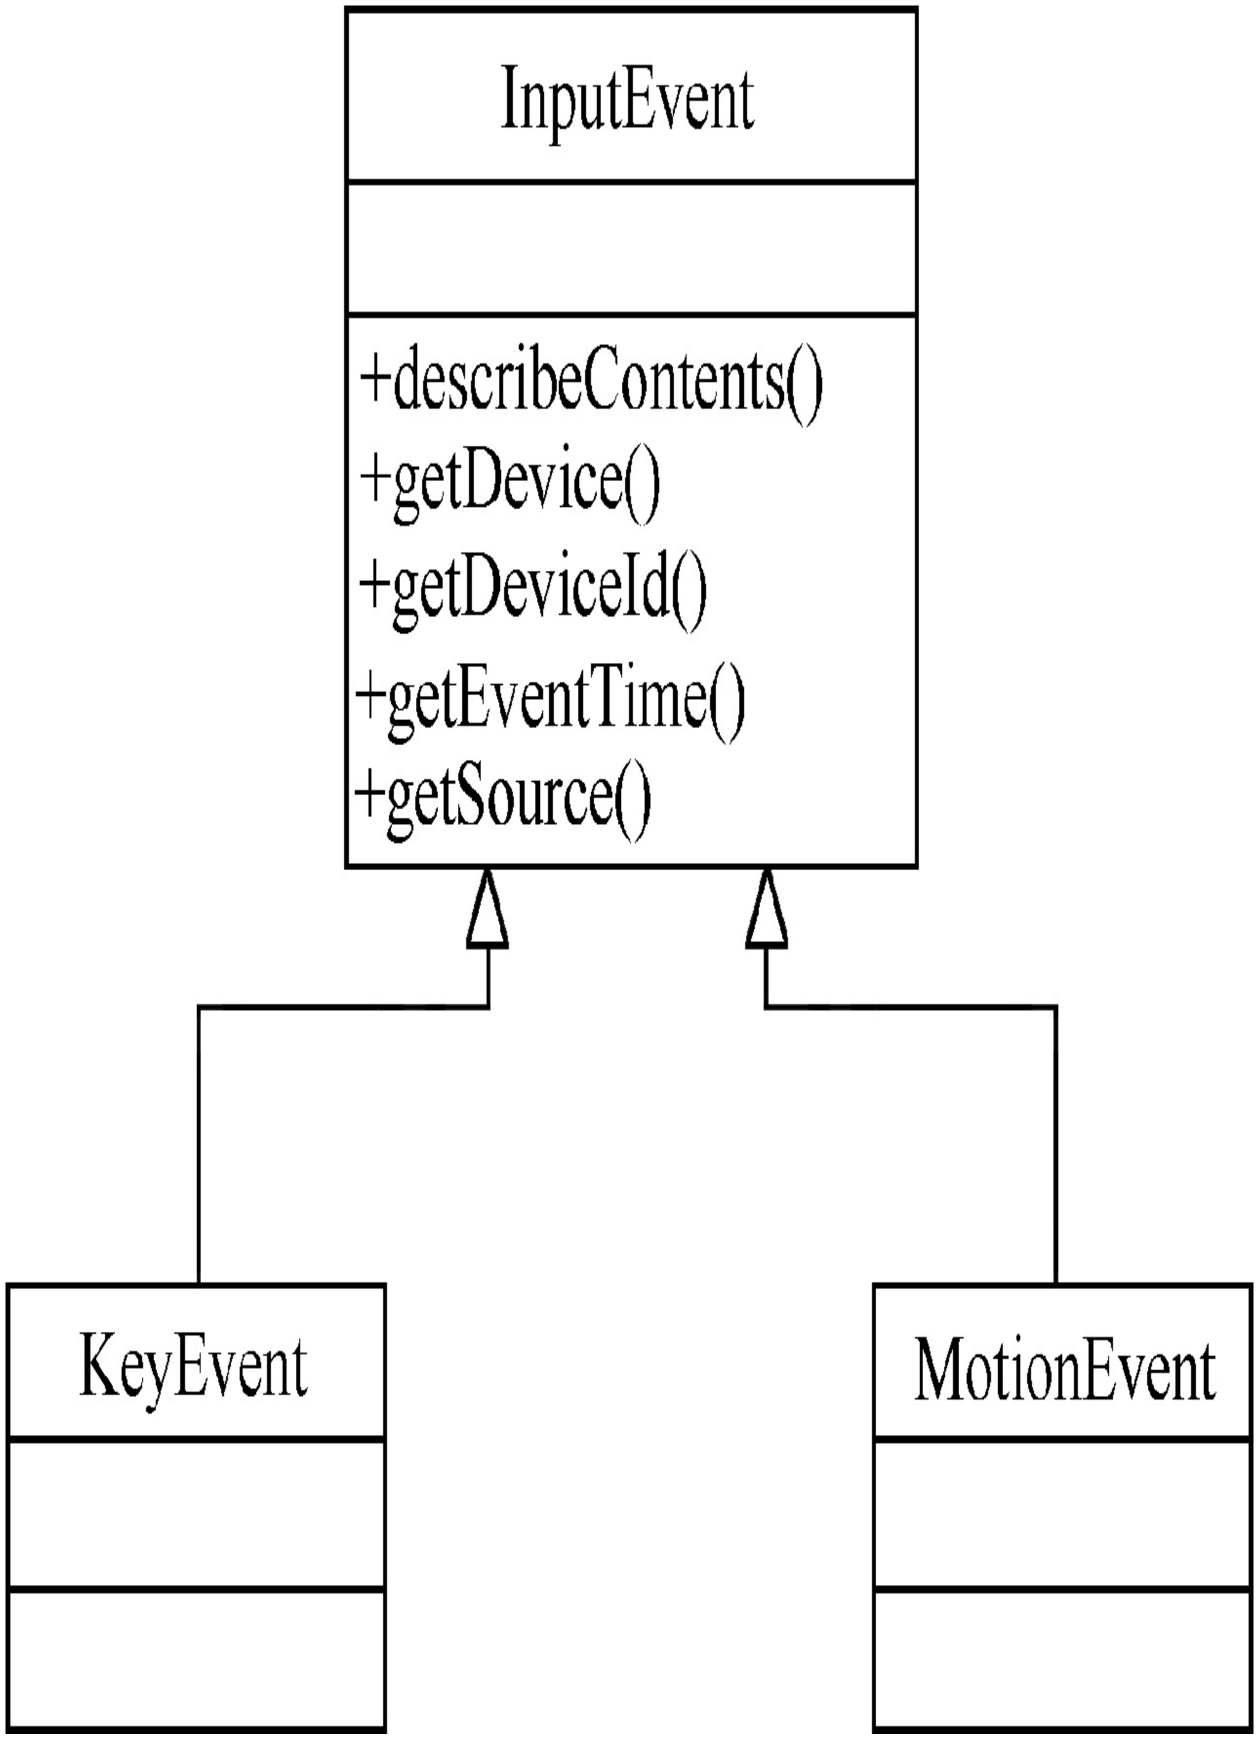
InputEvent
+describeContents()
+getDevice()
+getDeviceId()
+getEventTime()
+getSource()
KeyEvent
MotionEvent

▲图12-2　Android系统中的事件类关系图

InputEvent提供了几个非常通用的接口。比如getDevice()函数，可以得到当前事件的“硬件源”。其返回值为InputDevice类型，目前支持的设备包括：

SOURCE_UNKNOWN；

SOURCE_KEYBOARD；

SOURCE_DPAD；

SOURCE_GAMEPAD；

SOURCE_TOUCHSCREEN；

SOURCE_MOUSE；

SOURCE_STYLUS；

SOURCE_TRACKBALL；

SOURCE_TOUCHPAD；

SOURCE_TOUCH_NAVIGATION；

SOURCE_JOYSTICK；

SOURCE_ANY。

可以看到，以上这些Device类型基本涵盖了市面上所有常见的输入设备。

本小节的最后，我们来看看上层应用程序是如何参与事件处理的。换句话说，它们是如何获知事件的产生的？

对于应用开发人员来说，他们与事件的“直接接触”一般都是通过View组件进行的。比如：

- setOnKeyListener(OnKeyListener);
- setOnTouchListener(OnTouchListener);
- setOnGenericMotionListener(OnGenericMotionListener);
- setOnHoverListener(OnHoverListener);
- setOnDragListener(OnDragListener);

  ...

值得一提的是，虽然上面的接口都是通过回调的形式实现的，但这并不是唯一的方法。比如还可以通过重载View类里的函数来完成同样的功能。图12-3体现了这两种方法的区别。

很显然，图中所示的两种方式各具特点，开发人员应该根据实际情况来选择。

监听函数中会带有此Event相关的信息，以供应用程序可以正确处理它们。比如KeyEvent的监听函数：

```
public interface OnKeyListener {
     boolean onKey(View v, int keyCode, KeyEvent event);
}
```

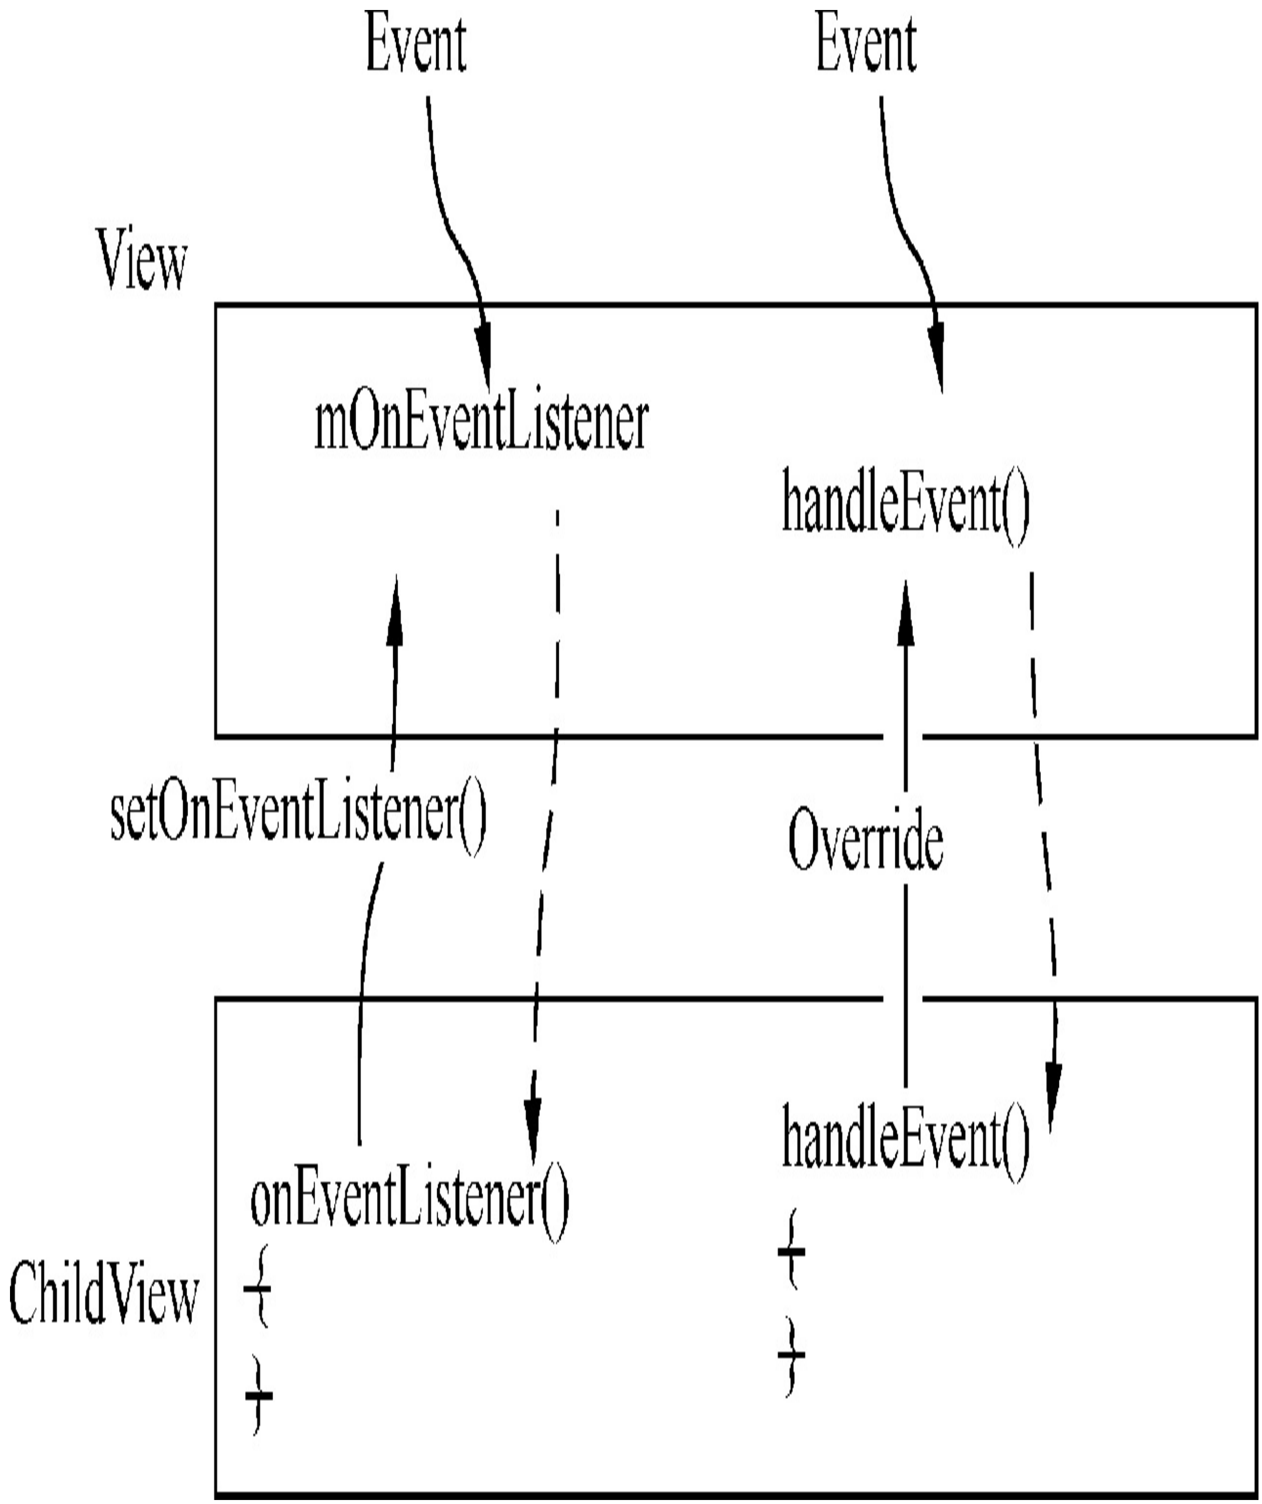

▲图12-3　事件处理的两种方法

整个接口的定义很简洁，各参数含义如下。

View：处理此KeyEvent的View对象。

keyCode：具体对应的是哪个物理按键，如数字键1、英文键E、特殊按键F1、相机按键Camera等。

KeyEvent：事件描述体，通过这个变量可以获取到更多的按键事件信息，如getRepeatCount()、getScanCode()、getSource()等。

12.2　事件的投递流程

上一节我们对系统中的事件进行了分类和梳理（特别是从硬件源的角度区分出了事件的种类）。另外，我们还从应用开发者的角度分析了如何去监听和响应这些事件。

从中可以发现Android系统提供的监听函数非常多，那么究竟这些接口与具体的“硬件源”之间有什么确切的关联呢？

解决这个问题的关键就是要理清事件的投递流程。

总体来说，Android输入事件投递系统的工作流程分为4个部分，如图12-4所示。

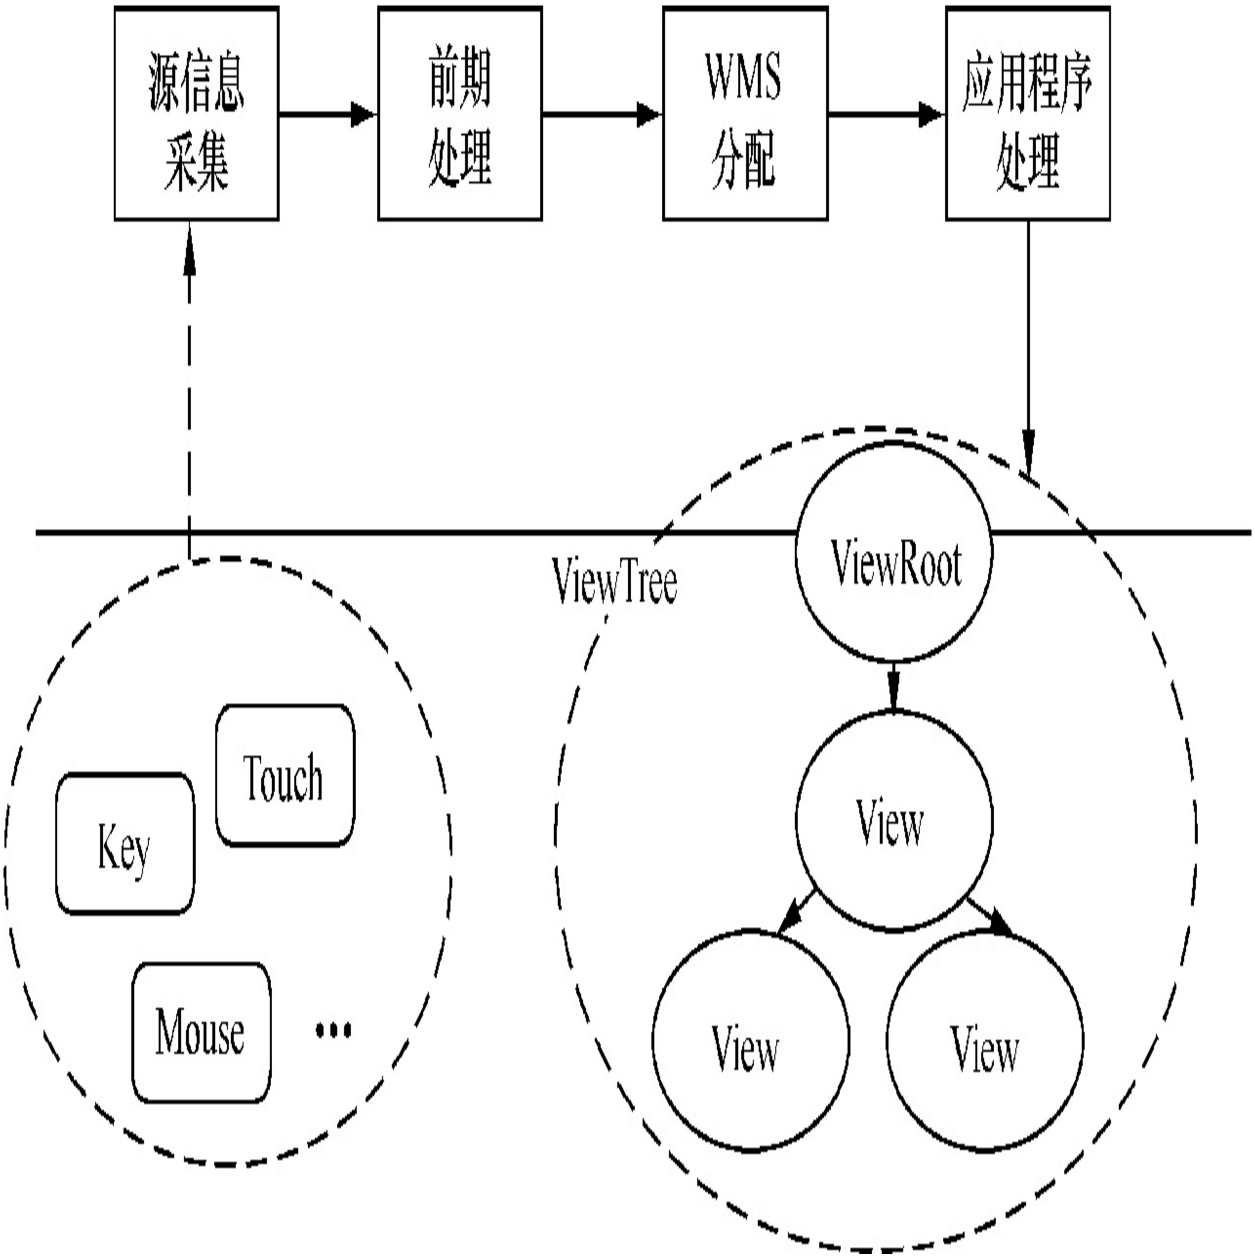

▲图12-4　事件处理系统工作流程图

按照事件的处理顺序分别是：

- 采集

即对“硬件源”所产生的原始信息进行收集的过程。它需要Linux内核驱动的支持，Android系统则通过/dev/input下的节点来访问当前发生的事件。

- 前期处理

我们称上一步采集到的信息为“原始数据”——这其中有一部分内容对应用程序而言并不是“必需”的，而且格式上也相对烦琐，所以需要先经过前期的提炼和转化。

- WMS分配

WindowManagerService是窗口的大主管，同时也是InputEvent的派发者。这样的设计是自然而然的，因为WMS记录了当前系统中所有窗口的完整状态信息，所以也只有它才能判断出应该把事件投递给哪一个具体的应用进程进行处理。其派发策略也因事件类别的不同而有所差异——比如说按键消息直接发送给“最前端”的窗口即可；而如果是触摸消息则要先计算出触摸点落在哪个区域，然后才能传递给相应的窗口单元。

- 应用程序处理

应用开发人员的工作主要体现在这一部分。经过前面几个步骤的传递，应用程序端接收到的事件已经相对“可理解”“好处理”了。接下来要做的，就是充分利用这些事件来实现软件功能。

12.2.1 InputManagerService

InputManagerService(IMS)的创建过程和WindowManagerService类似，都由SystemServer统一启动：

```
/*frameworks/base/services/java/com/android/server/SystemServer.j
     public void run() {…
          inputManager = new InputManagerService(context, wmHandl
          wm = WindowManagerService.main(context, power, display,
                        wmHandler,factoryTest != SystemServer.FAC
                                                  !firstBoot, onl
          ServiceManager.addService(Context.WINDOW_SERVICE, wm);
          ServiceManager.addService(Context.INPUT_SERVICE, inputM
          …
          inputManager.setWindowManagerCallbacks(wm.getInputMonit
          inputManager.start();
```

由上述代码段也可以看出，InputManagerService与

WindowManagerService有紧密的联系——前者的实例直接传入后者，以便后续调用。另外，IMS也将自己注册到了ServiceManager中，名称为Context.INPUT_SERVICE=“input”。

那么，InputManagerService.start()是否另外开启了一个工作线程？

```
    /*frameworks/base/services/java/com/android/server/input/Inpu
    public void start() {
           Slog.i(TAG, "Starting input manager");
           nativeStart(mPtr);//本地函数
           …
    }
```

Java层的IMS实际上是对Native层InputManager的一层Java包装，因而这个类的实现中有大量的本地函数声明。上述函数start直接调用了本地实现nativeStart。其中变量mPtr是IMS在构造过程中，调用nativeInit所创建的NativeInputManager对象——本质上是一个C++指针，所以可通过int类型进行保存：

```
/*frameworks/base/services/jni/com_android_server_input_InputMana
static void nativeStart(JNIEnv* env, jclass clazz, jint ptr) {
    NativeInputManager* im = reinterpret_cast<NativeInputManager*
    ptr指针强制类型转换为NativeInputManager对象*/
    status_t result = im->getInputManager()->start();/*getInputMa
    Manager成员变量(InputManager对象)，所以最终将执行的是InputManager.s
    …
}
```

如前面所述，IMS在Native层的实现主体是InputManager，如start：

```
/*frameworks/base/services/input/InputManager.cpp*/
status_t InputManager::start() {
status_t result = mDispatcherThread->run("InputDispatcher",PRIORI
    …
    result = mReaderThread->run("InputReader", PRIORITY_URGENT_DI
    …
    return OK;
}
```

果然，InputManager为IMS创建了新的线程，而且还是两个：

- InputReaderThread；
- InputDispatcherThread。

从名称中可以看出，它们一个负责“Reader”（从驱动节点中读取Event），另一个则专职“Dispatcher”（分发）。接下来我们将分别介绍这两个线程。

12.2.2 InputReaderThread

InputReaderThread概括起来就是一个独立的循环线程加上一些必要的辅助类。它的工作相对单一，即不断地轮询相关设备节点是否有新的事件发生：

```
/*frameworks/base/services/input/InputReader.h*/
class InputReaderThread : public Thread { //继承自Thread
public:
    InputReaderThread(const sp<InputReaderInterface>& reader);
    virtual ~InputReaderThread();
private:
    sp<InputReaderInterface> mReader; //辅助类
    virtual bool threadLoop();
};
```

InputReaderThread中的实现核心是InputReader类。这一部分的代码比较简单，我们不进行具体分析，但有几个重点需要大家了解：

- InputReader实际上并不直接去访问设备节点，而是通过EventHub来完成这一工作；
- EventHub通过读取/dev/input/下的相关文件来判断是否有新事件，并通知InputReader。

12.2.3 InputDispatcherThread

从InputManagerService的构造过程中，我们可以知道InputDispatcherThread和InputReaderThread一样，也是一个独立的线程，而且和WindowManagerService都运行于系统进程中。另外，InputDispatcherThread中的实现核心是InputDispatcher类。

InputDispatcherThread将与InputReaderThread协同工作，以保证

事件的正确派发和处理。那么，它们具体又是怎么做的呢？

还记得是谁创建了这两个线程的吗？可以先来看看InputManager中是否对它们进行了统一管理：

```
/*frameworks/base/services/input/InputManager.cpp*/
InputManager::InputManager(const sp<EventHubInterface>& eventHub,
                     const sp<InputReaderPolicyInterface>& reader
                     const sp<InputDispatcherPolicyInterface>& di
    mDispatcher = new InputDispatcher(dispatcherPolicy);
    mReader = new InputReader(eventHub, readerPolicy, mDispatcher
    /*将InputReader与InputDispatcher建立关联*/
    initialize();
}
```

可见InputReader在创建之初就与InputDispatcher产生了紧密的关联，这是它们后期协作的一个重要基础。比如在InputReader的loopOnce()循环中，会把发生的事件通过InputDispatcher实例告知Listener：

```
/*frameworks/base/services/input/InputReader.cpp*/
void InputReader::loopOnce() {…
     mQueuedListener->flush(); //这个变量实质上是上面mDispatcher的进一
     …
}
```

这样，InputDispatcher就能源源不断地获知系统设备中实时发生的事件了。而且它还可以向InputReader注册监听多种事件。相关的callback函数如下所示：

```
notifyConfigurationChanged(const NotifyConfigurationChangedArgs*)
notifyKey(const NotifyKeyArgs*);
notifyMotion(const NotifyMotionArgs*);
notifySwitch(const NotifySwitchArgs*);
notifyDeviceReset(const NotifyDeviceResetArgs*);
```

下面我们以notifyKey为例来分析一下具体的处理过程，如图12-5所示。

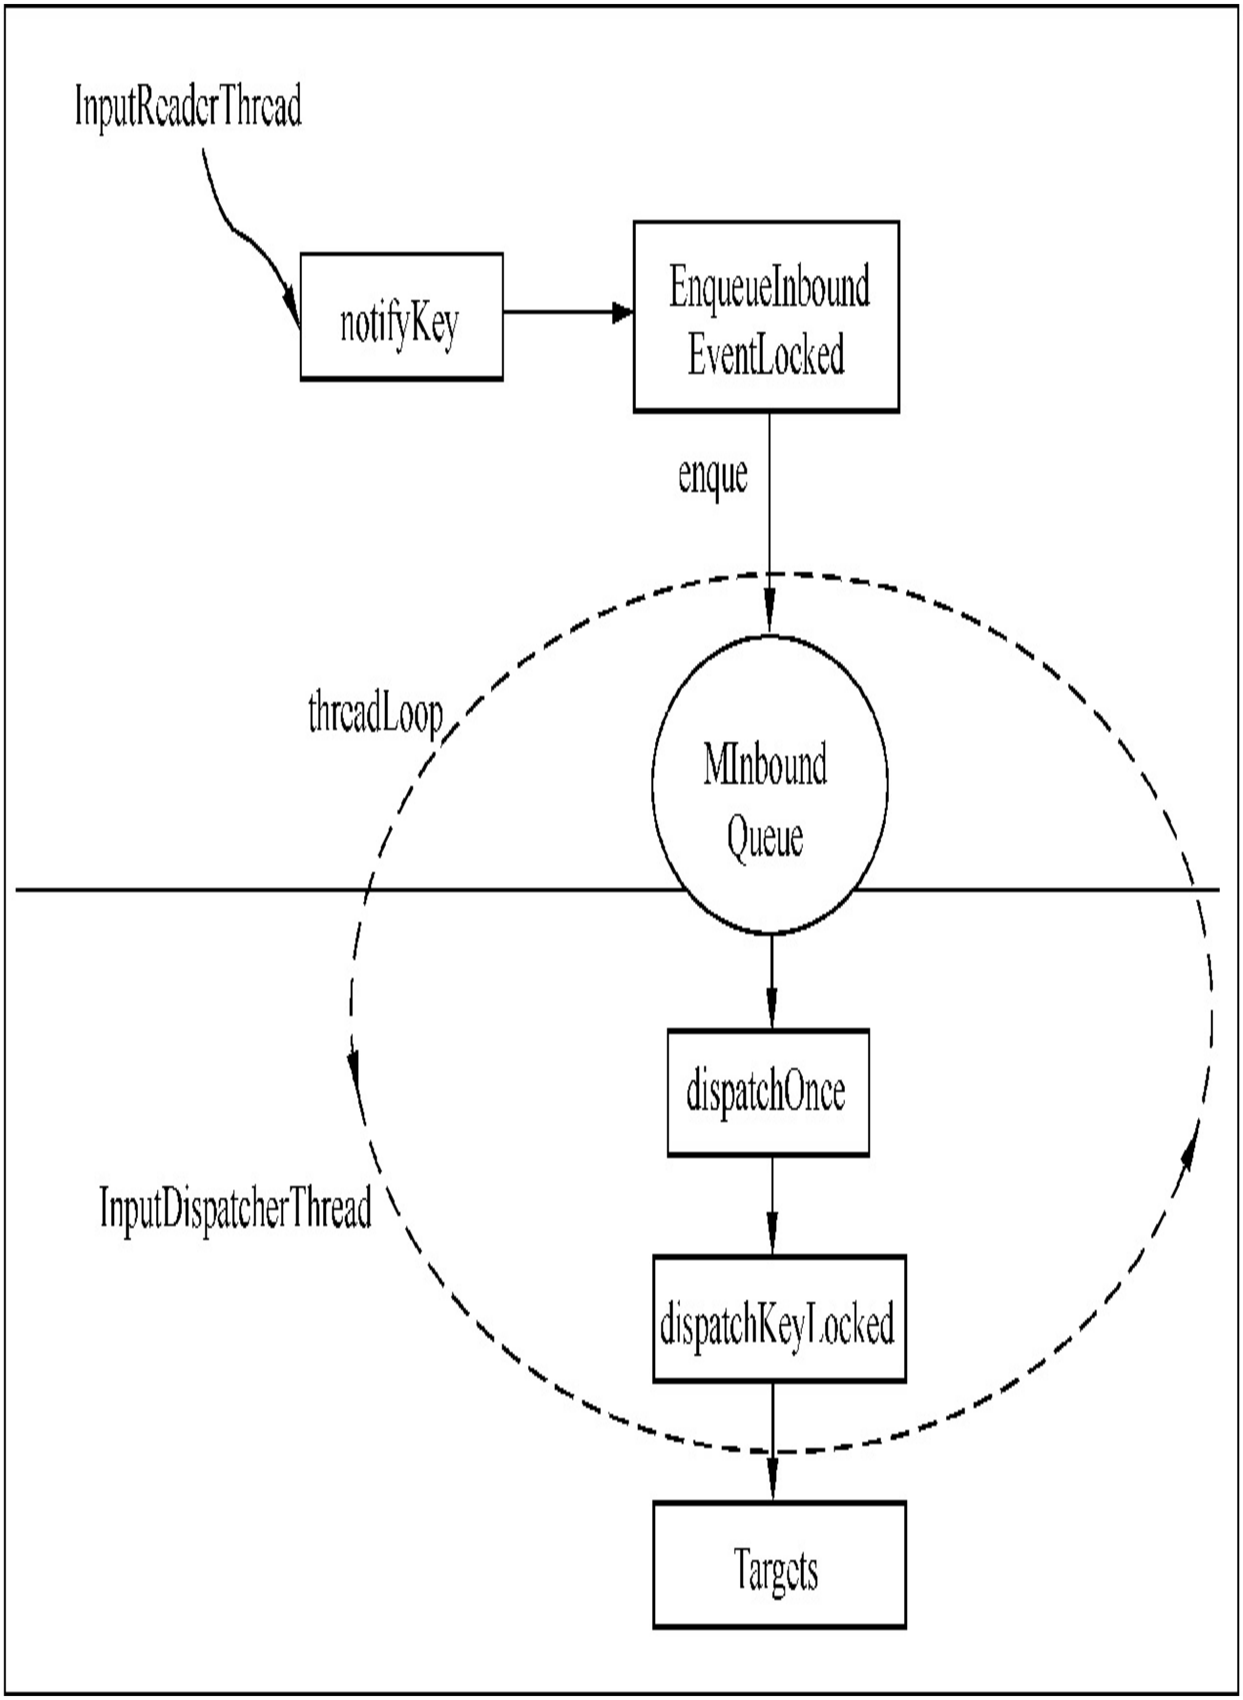
InputReaderThread
notifyKey
EnqueueInbound
EventLocked
enque
threadLoop
MInbound
Queue
dispatchOnce
InputDispatcherThread
dispatchKeyLocked
Targets

▲图12-5　InputDispatcher线程对事件的处理

图12-5中与“分发”策略有直接关联的是dispatchKeyLocked。其核心源码如下：

```
/*frameworks/base/services/input/InputDispatcher.cpp*/
bool InputDispatcher::dispatchKeyLocked(nsecs_t currentTime, KeyE
* dropReason, nsecs_t* nextWakeupTime) {
    /*Step1. 前期处理，主要针对按键的repeatCount */
    …//代码省略

    /*Step2.检查是否INTERCEPT_KEY_RESULT_TRY_AGAIN_LATER。如果是的话，
      要求与否——如果不满足的话，直接返回*/
    …//代码省略

    /*Step3.在将事件发送出去前，先要检查当前系统策略(Policy)是否要对它进行
      Home，就需要先由WMS来处理*/
    …//代码省略

    /*Step4.判断是否要放弃当前事件*/
    …//代码省略

    /*Step5.确定事件的接收方(Targets)。这是最重要的一步*/
    Vector<InputTarget> inputTargets;
    int32_t injectionResult = findFocusedWindowTargetsLocked(curr
                                                        input Targets
     /*查找符合要求的事件投递目标，下面会针对这个函数进行分析*/
    …
    setInjectionResultLocked(entry, injectionResult);
    …
    dispatchEventLocked(currentTime, entry, inputTargets);/*Step6
    return true;
}
```

上述函数很长，为了让大家能对处理流程“一目了然”，我们只保留了其中的核心部分，并对每一个步骤都做了适当的阐述。可以看出，Step1～Step4都可以算是“前期工作”，包括预处理、事件拦截、Policy的应用等。

需要大家特别关注的是Step5，即InputDispatcher如何查找与当前按键事件匹配的目标呢？前面我们说过，对于按键消息而言，只要找到“最前端”的窗口即可。当然，实际的处理过程会稍微复杂些，如下所示：

```
int32_t InputDispatcher::findFocusedWindowTargetsLocked(nsecs_t c
EventEntry* entry, ector<InputTarget>& inputTargets, nsecs_t* nex
    int32_t injectionResult;
    if (mFocusedWindowHandle == NULL) {/*如果当前并没有“最前端”（即获
    按照Android系统中的作法，会丢弃这一事件。变量mFocusedWindowHandle代
        if (mFocusedApplicationHandle != NULL) {
          injectionResult = handleTargetsNotReadyLocked(currentTi
                                mFocusedApplicationHandle, NULL,
                          /*如果没有“最前端”的窗口，但却有“最前端”的应用
                                程序还在启动过程中，因而先等待一段时间后
           goto Unresponsive;
        }
        …
        injectionResult = INPUT_EVENT_INJECTION_FAILED;
        goto Failed;/*既没有焦点窗口，也没有焦点应用的情况，程序将报错*/
    }
    /*执行到这里说明当前有焦点窗口*/
    if (! checkInjectionPermission(mFocusedWindowHandle, entry->i

          injectionResult = INPUT_EVENT_INJECTION_PERMISSION_DENI
          goto Failed;
    }

    /*如果当前窗口处于暂停状态，也需要等待*/
    if (mFocusedWindowHandle->getInfo()->paused) {…
    }
    /*当前窗口还在处理上一个事件，和上面一样，都需要等待它完成*/
    if (!isWindowReadyForMoreInputLocked(currentTime, mFocusedWin
    }

    /*成功找到符合要求的窗口，并且状态值都正确，此时可以将它加入inputTarget
    injectionResult = INPUT_EVENT_INJECTION_SUCCEEDED;
    addWindowTargetLocked(mFocusedWindowHandle,
                         InputTarget::FLAG_FOREGROUND | InputTarg
                         BitSet32(0), inputTargets);
Failed:
Unresponsive:
    /* …异常处理部分，代码略*/
}
```

读者可能会觉得奇怪，为什么InputDispatcher会有当前焦点窗口的句柄呢，是谁向它提供了这类信息？通过查找代码，可以发现mFocusedWindowHandle是由InputMonitor来赋值的——后面这个InputMonitor又扮演了什么样的角色呢？

简单来说，它是WMS与InputDispatcher之间的“中介”。

从源码的角度可分为两部分。

- InputDispatcher→ InputMonitor→WMS

它实现了IMS的WindowManagerCallbacks接口：

```
/*frameworks/base/services/java/com/android/server/input/InputMan
public interface WindowManagerCallbacks{
    public void notifyConfigurationChanged(); //输入设备的配置变更
    public void notifyLidSwitchChanged(long, boolean);//Lid开关
    public void notifyInputChannelBroken(InputWindowHandle); /*连
                                          用程序的Socket通道。接下来
    public long notifyANR(InputApplicationHandle, InputWindowHand
    Application Not Responding错误*/
    public int interceptKeyBeforeQueueing(KeyEvent, int, boolean)
    public int interceptMotionBeforeQueueingWhenScreenOff(int);
    public long interceptKeyBeforeDispatching(InputWindowHandle,
                         /*以上3个回调接口保证了WMS在消息处理中拥有绝对
    public KeyEvent dispatchUnhandledKey(InputWindowHandle, KeyEv
                         按键事件在整个投递流程中没有得到任何处理，这时要
    public int getPointerLayer();
}
```

- WMS→InputMonitor→InputDispatcher

除了上述回调接口外，InputMonitor也为WMS访问InputDispatcher提供了一系列的函数实现。比如InputDispatcher中的当前焦点窗口，就是WMS通过InputMonitor的updateInputWindowsLw()告知的。

现在我们已经清楚WMS与InputDispatcher、InputReader三者间的交互关系了。最后还有一个问题，就是InputDispatcher是如何通知应用程序窗口有按键事件的。换句话说，它和InputTarget之间是如何通信的？

```
/*frameworks/base/services/input/InputDispatcher.h*/
struct InputTarget {
    enum {/*这个枚举类型里是关于目标窗口的各种属性值描述*/
          FLAG_FOREGROUND = 1 << 0, //说明目标窗口是前台应用
          …//其他FLAGS省略
    };
    /*就是这里了，InputDispatcher通过inputChannel与窗口建立连接*/
    sp<InputChannel> inputChannel;
    …
```

```
}
```

在Android系统中，进程间的通信大多是基于Binder机制的。而InputDispatcher和应用程序之间肯定也是跨进程的，那么这个InputChannel是不是Binder Server呢？

这是一个合理的猜测，不过事实并非如此。我们来看看它的类型定义就知道了：

```
/*frameworks/base/include/androidfw/InputTransport.h */
class InputChannel : public RefBase {
protected:
    virtual ～InputChannel();
public:
    InputChannel(const String8& name, int fd);/*构造函数中传入的是in
                                              有点类似于文件描述符*/
    static status_t openInputChannelPair(const String8& name, sp<
                outServerChannel,sp<InputChannel>& outClientChann
                                             一个Channel对(因为是双
    …
    status_t sendMessage(const InputMessage* msg);
    status_t receiveMessage(InputMessage* msg);
    /*发送和接收消息*/
private:
    String8 mName; //通道名称
    int mFd; //重点就是这个int类型代表的是什么
};
```

既然InputDispatcher是通过channel通道与应用程序进行通信的，那么每增加一个应用程序窗口，都得新建一对InputChannel。这样我们就可以从WMS新增窗口的相关代码入手，进而理清整个过程：

```
/*frameworks/base/services/java/com/android/server/wm/WindowManag
public int addWindow(Session session, IWindow client, int seq, Wi
int viewVisibility, int displayId, Rect outContentInsets, InputCh
{
     …
     String name = win.makeInputChannelName(); //为当前的通道取名
     InputChannel[] inputChannels = InputChannel.openInputChannel
     /*打开一对通道*/
     …
}
```

经过JNI及一系列函数调用，打开通道的本地实现代码如下：

```
/*frameworks/base/include/androidfw/InputTransport.cpp*/
status_t InputChannel::openInputChannelPair(const String8& name,s
outServerChannel,
 sp<InputChannel>& outClientChannel) {
    int sockets[2];/*终于水落石出了，原来是通过Unix Domain Socket实现的
    if (socketpair(AF_UNIX, SOCK_SEQPACKET, 0, sockets)) {/*本篇的
    已经介绍过Unix Domain Socket的使用方法了。这里唯一的不同就是直接采用了
    而简化了双方通信的工作 */
          status_t result = -errno;
          …
          return result;
    }

    int bufferSize = SOCKET_BUFFER_SIZE;
    setsockopt(sockets[0], SOL_SOCKET, SO_SNDBUF, &bufferSize, si
    setsockopt(sockets[0], SOL_SOCKET, SO_RCVBUF, &bufferSize, si
    setsockopt(sockets[1], SOL_SOCKET, SO_SNDBUF, &bufferSize, si
    setsockopt(sockets[1], SOL_SOCKET, SO_RCVBUF, &bufferSize, si
               /*设置通信双方各自的缓冲区大小*/
    String8 serverChannelName = name;
    serverChannelName.append(" (server)");
    outServerChannel = new InputChannel(serverChannelName, socket
                字是在WMS传过来的名称基础上再加上后缀。并且在以后的通信中使
    String8 clientChannelName = name;
    clientChannelName.append(" (client)");
    outClientChannel = new InputChannel(clientChannelName, socket

    return OK;
}
```

通过这个函数的分析可知，InputChannel中的mFd实际上是socket编号。

至此，InputReader、InputDispatcher、WMS和应用程序的关系已经剖析清楚了。读者在理解了这四者间的关系后，可以有针对性地再自行分析其他事件的处理流程。

12.2.4 ViewRootImpl对事件的派发

到目前为止，我们的分析已经覆盖了Android事件投递系统的前3部分，最后就只剩下应用程序这边的处理了。一方面，ViewRootImpl是WMS与应用程序窗口间的“桥梁”，就如InputMonitor与WMS之间的关系一样；另一方面，ViewRootImpl还是应用进程中担当事件派发与管理的最佳“人”选。

接着前一小节的讲解，当有事件产生后，InputDispatcher会通知到相应的接收者；而后者则负责对事件做进一步的派发与处理。在ViewRootImpl中，一旦获知InputEvent，它首先调用enqueueInputEvent进行事件“入队”。此时分为两种情况。

- 紧急事件

如果是“紧急事件”，变量processImmediately为true，那么enqueueInputEvent会直接调用doProcessInputEvents进行处理。

- 其他事件

如果事件本身并不是“刻不容缓”的，那么enqueueInputEvent会通过scheduleProcessInput Events来把这个InputEvent推送到消息队列中，然后按顺序处理。

无论是哪一种情况，ViewRootImpl都需要（只是处理顺序的差异）对这一InputEvent进行派发，并最终由ViewTree中的某一特定View对象来做具体的事件处理。详细流程在前一节已经讨论过，这里不再赘述。

12.3 事件注入

正常情况下，Android系统中的各种Event是由用户主动发起而产生的。譬如用户点击设备屏幕产生的触屏事件；按压物理按键产生的KeyEvent等。但是，在某些特殊的情况下（比如自动化测试的场景下），我们希望可以通过程序来模拟用户的上述行为，此时就需要事件注入技术了。

事件注入的方式有很多种，包括但不限于：

- 通过Input Manager提供的内部API接口

Input Manager提供了让开发者可以注入事件的接口，描述如下：

```
/*frameworks/base/core/java/android/hardware/input/InputManager.j
/**
     * Injects an input event into the event system on behalf of
     …
     *
     * @hide
     */
    public boolean injectInputEvent(InputEvent event, int mode) {
```

不过这个接口是hide的，意味着普通的开发者无权在应用程序中使用它(当然，这并不是绝对的，在某些Android版本中我们可以通过一些特殊的方法来绕过这些限制)。因而这种方式较常见于Android工程自身的各个模块中，比如下面的例子摘自hdmi server的实现中：

```
    static void injectKeyEvent(long time, int action, int keycode
        KeyEvent keyEvent = KeyEvent.obtain(time, time, action, k
             repeat, 0, KeyCharacterMap.VIRTUAL_KEYBOARD, 0, KeyE
             InputDevice.SOURCE_HDMI, null);
        InputManager.getInstance().injectInputEvent(keyEvent,
                                InputManager.INJECT_INPUT_EVENT_M
        keyEvent.recycle();
   }
```

- 利用Instrumentation提供的接口

Instrumentation也提供了一些辅助事件注入的接口，譬如：

```
/*frameworks/base/core/java/android/app/Instrumentation.java*/
/**
     * Sends an up and down key event sync to the currently focus
     *
     * @param key The integer keycode for the event.
     */
    public void sendKeyDownUpSync(int key) {
        sendKeySync(new KeyEvent(KeyEvent.ACTION_DOWN, key));
        sendKeySync(new KeyEvent(KeyEvent.ACTION_UP, key));
}
```

这种方式比第一种在使用上方便一些，但缺点很明显，就是只对本应用程序自己有效。换句话说，如果我们面临的是跨应用进程的测试场景则无法起到任何作用。

- 通过system/bin目录下的input程序

System/bin目录下保存着一系列非常有用的程序，如monkey、am、dex2oat等，其中与事件注入相关的是input。如图12-6所示。

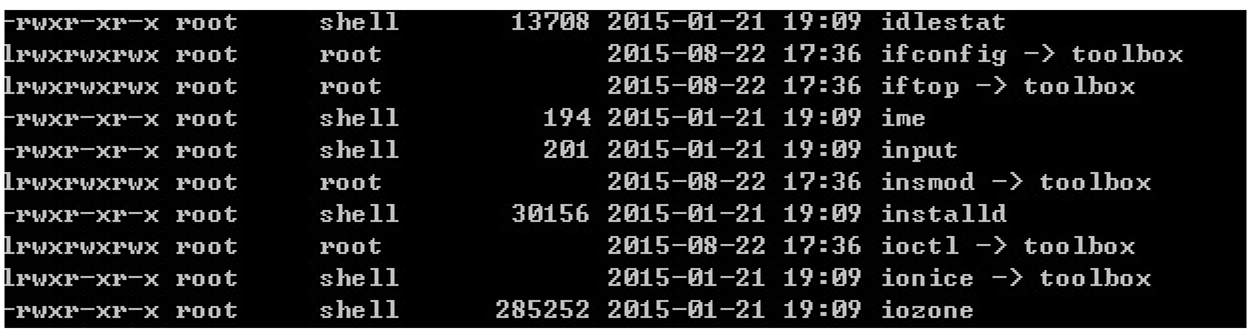

```
-rwxr-xr-x root      shell      13708 2015-01-21 19:09 idlestat
lrwxrwxrwx root      root             2015-08-22 17:36 ifconfig -> toolbox
lrwxrwxrwx root      root             2015-08-22 17:36 iftop -> toolbox
-rwxr-xr-x root      shell        194 2015-01-21 19:09 ime
-rwxr-xr-x root      shell        201 2015-01-21 19:09 input
lrwxrwxrwx root      root             2015-08-22 17:36 insmod -> toolbox
-rwxr-xr-x root      shell      30156 2015-01-21 19:09 installd
lrwxrwxrwx root      root             2015-08-22 17:36 ioctl -> toolbox
lrwxr-xr-x root      shell            2015-01-21 19:09 ionice -> toolbox
-rwxr-xr-x root      shell     285252 2015-01-21 19:09 iozone
```

▲图12-6　相关的input

我们可以通过adb shell来使用这个input工具。如果不知道命令格式的话，可以查询它的帮助，如图12-7所示。

```
C:\Users\xs0>adb shell
shell@hwmt7:/ $ input
input
Usage: input [<source>] <command> [<arg>...]

The sources are:
      trackball
      joystick
      touchnavigation
      mouse
      keyboard
      gamepad
      touchpad
      dpad
      stylus
      touchscreen

The commands and default sources are:
      text <string> (Default: touchscreen)
      keyevent [--longpress] <key code number or name> ... (Default: keyboard)
      tap <x> <y> (Default: touchscreen)
      swipe <x1> <y1> <x2> <y2> [duration(ms)] (Default: touchscreen)
      press (Default: trackball)
      roll <dx> <dy> (Default: trackball)
```

▲图12-7　帮助

举一个例子来说，通过下面的语句可以向设备发送一个HOME按键事件，使系统回到主界面：

```
input keyevent 3
```

其中数字3对应的是HOME按键。其他数值与具体功能的对应关系可以通过阅读源码获得。

- 直接写入数据到/dev/input/eventX节点中

我们知道，input目录下的节点是kernel向Android提供事件信息的“桥梁中介”，因而直接向这些eventX写入数据相当于从“源头”来控制事件的产生。也正是因为这个原因，Android系统为这些节点设置了较高的权限，禁止普通的应用程序直接向它们注入数据，如图12-8所示。

```
shell@hwmt7:/dev/input $ ll
ll
crw-rw---- root     input     13,  64 2015-09-14 07:16 event0
crw-rw---- root     input     13,  65 2015-09-14 07:16 event1
crw-rw---- root     input     13,  66 2015-09-14 07:16 event2
crw-rw---- root     input     13,  67 2015-09-14 07:16 event3
crw-rw---- root     input     13,  68 2015-09-14 07:16 event4
crw-rw---- root     input     13,  69 2015-09-14 07:16 event5
crw-rw---- root     input     13,  63 2015-09-14 07:16 mice
crw-rw---- root     input     13,  32 2015-09-14 07:16 mouse0
crw-rw---- root     input     13,  33 2015-09-14 07:16 mouse1
```

▲图12-8　输出界面

所以，如果希望采用这种方式来完成事件的注入，那么需要对Android设备做一些特殊的处理。大家可以自行查阅相关资料来做一下验证。

第13章
应用不再同质化——音频系统

对于一部嵌入式设备来说，除了若干基础功能外（比如手机通话、短信），最重要的可能就是多媒体了——首先我们要问自己一个简单的问题：什么是多媒体呢？

这个术语对应的英文单词是“Multi-Media”，直译过来就是多媒体——名称本身很好地解释了它的含义，我们也可以参见Wikipedia上的详细定义。

```
Multi-media is media and content that uses a combination of diffe
bination of text, audio, still images, animation, video, or inter
```

通俗地讲，Multi-media是多种形式的媒体内容（比如文本、音频、视频、图片、动画等）的组合。可以说，它是一款产品能否在众多“同质化”严重的市场中脱颖而出的关键。另外，由于不同的产品在音频处理、视频解码等芯片方面或多或少都存在差异，原生态的Android系统不可能覆盖市面上的所有硬件方案，所以这部分功能的移植与二次开发就成了设备研发中的重头戏——当然，Android系统在设计之初也充分考虑到了这点，它提供了一整套灵活的多媒体解决方案，以应对厂商的定制化需求。

对于应用开发人员来说，多媒体的另一个“代名词”或许可以说是“MediaPlayer和MediaRecorder”（这样说多少有点“武断”，不过是很多开发人员的共识），而深藏在这两个类中的实现细节却鲜有人知。这也是Android的一大优点——高度封装，让研发人员可以把精力放在自己“需要做的事情上”，各司其职，从而极大地提高了产品的开

发效率。

不过，这种封装也同时让我们付出了一些代价。比如整个多媒体系统显得异常庞大，各种类定义、C++库、Java实现让人应接不暇——这无疑给大家剖析多媒体系统的内部实现带来了不少障碍。为此，本章特别选取音频系统（其中又以“音频回放”为分析核心）作为学习的重点。通过深入分析音频系统，来为大家理解Android多媒体系统打开一个“缺口”。

本章的内容编排是由下而上的，即从音频基础知识、底层框架讲起，然后才逐步扩展延伸到上层应用。其主要包括如下几个核心。

- 音频的基础知识

理解音频的一些基础知识，对于大家分析整个音频系统大有裨益。它可以让我们从实现的层面去思考音频系统的“目标是什么”，然后才是“怎么样去达到这个目标”。

- AudioFlinger，AudioPolicyService和AudioTrack/AudioRecorder

抛开MediaPlayer、MediaRecorder这些与应用开发有直接关联的部分，整个音频系统的核心就是由这三者构建而成的。其中前两者都属于System Service，驻留在mediaserver进程中，负责不断地处理AudioTrack/AudioRecorder的请求。另外，音频的“回放和录制”从总体流程上分析都是类似的，所以本章侧重于对回放过程的分析。

- 音频的数据流

数据流处理是音频系统管理的重点和难点之一，至少有以下几点是需要设计者充分考虑的（以音频回放为例）。

- 正确规划音频流的路径（AudioPolicy）

通常Android产品会配备多种音频回放设备（如喇叭、耳机、蓝牙等），而且同一个“时间点”系统也很可能会播放多种音频——我们如何正确处理音频的混音，并将结果输出到对应的音频回放设备中？

- 如何保证音频流以合理的速度传输到音频设备

显然，音频数据的太快或者太慢传输都会是缺陷。

- 跨进程的数据传递

从Apk应用程序创建一个MediaPlayer开始，到音频能真正从设备中回放出来，这个过程涉及多个进程间的通信。如何在这些进程之间做好数据的准确传递，也是设计者应该重点思考的。

- 音频系统的上层建筑

在理解了音频系统的实现核心后，我们再从上层应用的角度来思考：如何为应用开发人员提供简捷高效的“音频使用和控制”的解决方案。

13.1　音频基础

13.1.1　声波

从物理学的角度来说，声波是机械波的一种。

机械波（Mechanical Wave）是由机械振荡产生的，所以它的传播需要介质的支持。

另外，机械波还有如下特点。

- 介质本身并不会随着机械波不断地前进。比如我们抖动一条绳子产生的绳波，绳子上的某个点只是在一定范围内做上下运动，没有因为波的传递而脱离绳子。因而机械波是能量的传递，而不是质量的传递。
- 在不同的介质中，传播速度是不一样的。

那么，作为机械波的一种，声音有哪些重要属性呢？

- 响度（Loudness）

响度就是人类可以感知到的各种声音的大小，即俗称的“音量”。响度与声波的振幅有直接关系——理论上振幅越大，响度也就越大。

- 音调（Pitch）

我们常说某人唱高音很好，或者低音很棒，这就是音调。音调与声音的频率有关系——当声音的频率越大时，人耳所感知到的音调就越高，否则就越低。

- 音色（Quality）

同一种乐器使用不同的材质来制作，所表现出来的音色效果则不一样，这是由物体本身的结构特性所决定的——它直接影响了声音的音色属性。同样的道理，不同的演唱者因为他们发声部位的先天差异，从而造就了更具嗓音特色的音乐才子。

声音的这几个属性，是所有音频效果处理的基础。换句话说，任何对音频数据的调整手段最终都将反映到这些属性上。

13.1.2　音频的录制、存储与回放

上面我们对多媒体的定义还从侧面反映出一个结论，即Multi-Media并不是专门为计算机而生的——只不过后者的出现极大地推动了它的发展。那么，计算机领域的多媒体系统和传统的多媒体相比会有哪些区别呢？

一个很明显的问题是：我们如何将各种媒体源数字化呢？之所以有这个疑问，是因为早期的音频信息存储在录音带中，并以模拟信号的形式保存。而到了计算机时代，这些音频数据必须通过一定的处理手段才可能存储到设备中——这也是我们在数字化过程中会遇到的一个常见问题。

如图13-1所示就是音频从录制到播放的一个典型操作流程。

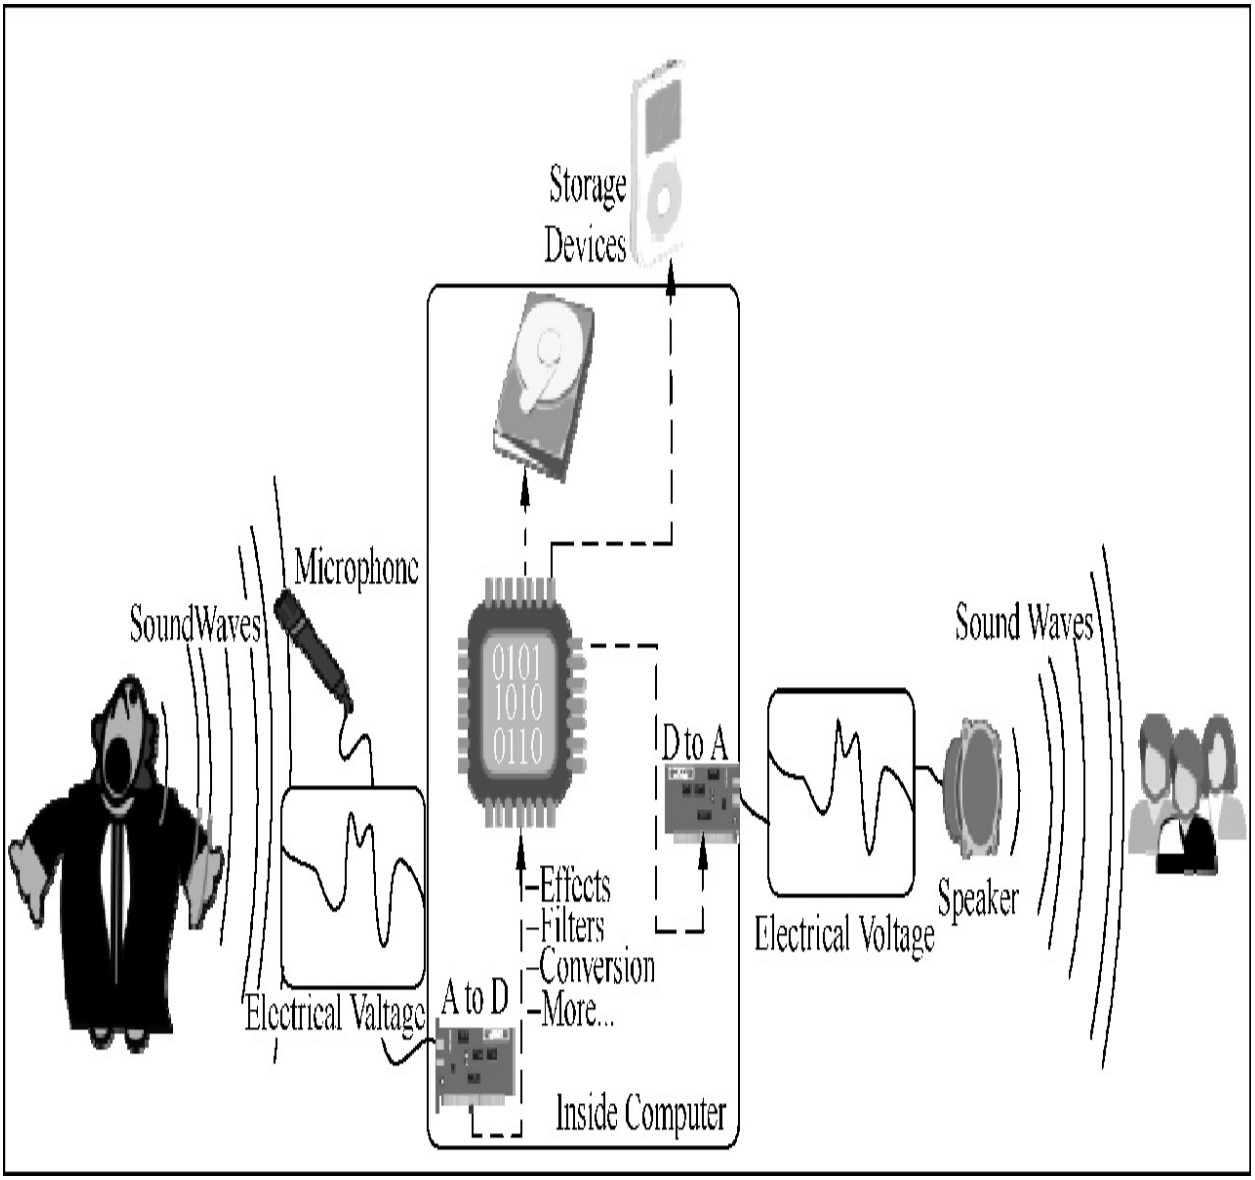

▲图13-1　音频的录制、存储和回放

引用自http://en.wikipedia.org/wiki/File:A-D-A_Flow.svg。

（1）录制过程

- 首先，音频采集设备（比如Microphone）捕获声音信息（初始数据是模拟信号）
- 采集到的模拟信号通过模-数转换器（ADC）处理成计算机能接受的二进制数据。

- 上一步得到的数据按照需求进行必要的渲染处理，如音效调整、过滤等。
- 处理后的音频数据理论上已经可以存储到计算机设备中了，如硬盘、USB设备等。不过由于这时的音频数据体积相对较大，不利于保存和传输，通常我们还会对其进行压缩处理。比如常见的mp3音乐，实际上就是对原始数据采用相应的压缩算法后得到的。压缩过程根据采样率、位深等因素的不同，最终得到的音频文件可能会有一定程度的失真。

另外，音视频的“编码和解码”既可以由纯软件处理，也可以借助于专门的硬件芯片来完成。

（2）回放过程

回放过程基本上是录制过程的逆向操作，即：

- 从存储设备中取出音频文件，并根据录制过程采用的编码方式进行对应的解码；
- 音频系统为这一播放实例选取最匹配的音频回放设备（比如耳机、喇叭、蓝牙）；
- 解码后的数据经过音频系统设计的路径进行传输；
- 音频数据信号通过数-模转换器（DAC）变换成模拟信号；
- 音频模拟信号经过回放设备，还原出原始声音；

本章着重讲解的是音频的“回放过程”。

13.1.3 音频采样

前面说过，数字音频系统需要将声波的波形信号通过ADC转换成计算机支持的二进制，进而保存成音频文件，这一过程叫做音频采样（Audio Sampling）。音频采样是众多数字信号处理的一种——不过它们的基本原理都是类似的（比如视频的采样和音频采样本质上没有太大区别）。

可想而知，采样（Sampling）的核心是把连续的模拟信号转换成离散的数字信号。它涉及如下几个因素。

- 样本（Sample）

　　即将被采样的原始资料，如一段连续的声音波形。

- 采样器（Sampler）

　　采样器是将样本转换成终态信号的关键。它可以是一个子系统，也可以指一个操作过程，甚至一个算法，取决于不同的信号处理场景。理想的采样器要求尽可能不产生信号失真。

- 量化（Quantization）

　　采样后得到的值还需要通过量化，即将连续值近似为某个范围内有限多个离散值的处理过程。原始数据是模拟的连续信号，而数字信号则是离散的，且数值表达范围是有限的，所以量化是必不可少的一个步骤。

- 编码（Coding）

　　在计算机的世界里，所有数值都是用二进制表示的，因而我们还需要把量化值进行二进制编码。这一步通常与量化同步进行。

　　整个流程如图13-2所示。

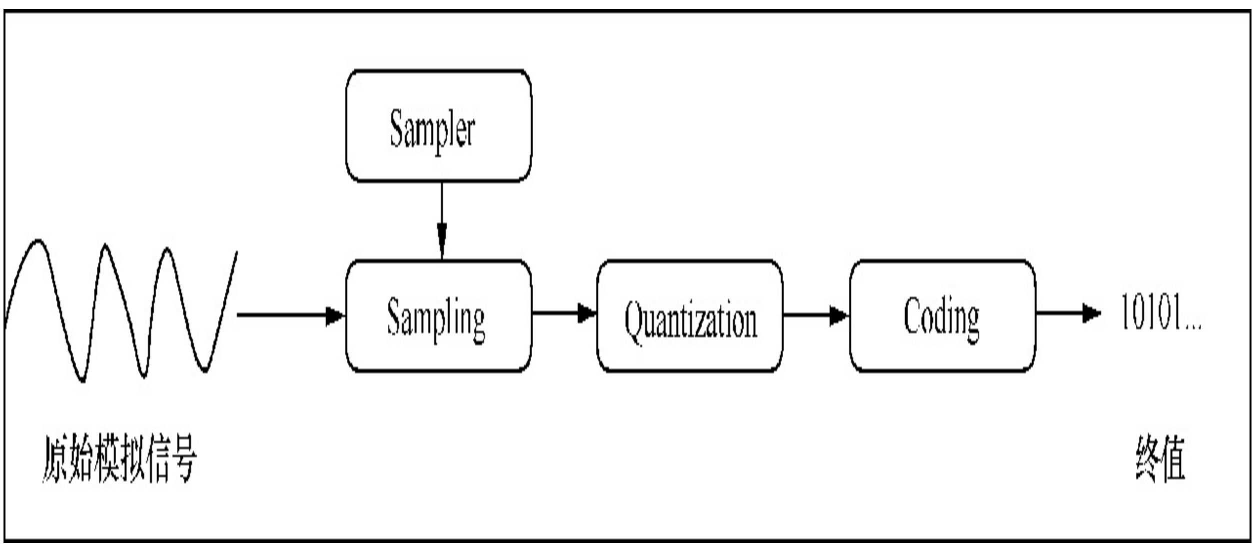

▲图13-2　PCM流程

PCM（Pulse-code modulation）俗称“脉冲编码调制”，是将模拟信号数字化的一种经典方式，得到非常广泛的应用。比如数字音频在计算机、DVD以及数字电话等系统中的标准格式采用的就是PCM。它的基本原理就是上面的几个流程，即对原始模拟信号进行抽样、量化和编码，从而产生PCM流。另外，我们可以调整PCM的以下属性来达到不同的采样需求。

- 采样速率（Sampling Rate）

在将连续信号转化成离散信号时，就涉及采样周期的选择。如果采样周期太长，虽然文件大小得到控制，但采样后得到的数据很可能无法准确表达原始信息；反之，如果采样频率过快，则最终产生的数据量会大幅增加。这两种情况都是我们不愿意看到的，因而在项目中需要根据实际情况来选择合适的采样速率。

由于人耳所能辨识的声音范围是20～20kHz，所以人们一般都选用44.1kHz(CD)，48kHz或者96kHz来作为采样速率。

- 采样深度（Bit Depth）

我们知道量化（Quantization）是将连续值近似为某个范围内有限多个离散值的处理过程。那么这个范围的宽度以及可用离散值的数量会直接影响到音频采样的准确性，这就是采样深度的意义。

图13-3是一个采用4位深度进行量化后得到的PCM。因为4bit最多只能表达16个数值（0～15），所以图中最终量化后的数值依次为7、9、11、12、13、14、15等。这样的结果显然是相对粗糙的，存在一定程度的失真。位深越大，所能表达的数值范围越广，上图中纵坐标的划分也就越细致，从而使得量化的值越接近原始数据。

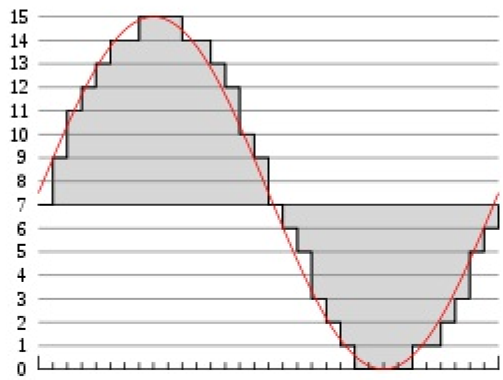

▲图13-3　采用4-bit深度的PCM范例 {-:-}（引自Wikipedia）

13.1.4　Nyquist－Shannon采样定律

“Nyquist－Shannon”是由Harry Nyquist和Claude Shannon总结出来的采样规律，为我们选择合适的采样频率提供了理论依据。这个规律又被称为“Nyquist sampling theorem”或者“The sampling theorem”，通常译为“奈奎斯特采样理论”。它的中心思想是：

“当对被采样的模拟信号进行还原时，其最高频率只有采样频率的一半。”

换句话说，如果我们要完整重构原始的模拟信号，则采样频率就必须是它的两倍以上。比如人的声音范围是20～20kHz，那么选择的采样频率就应该在40kHz左右——数值太小则声音将产生失真现象；数值太大一方面造成了资源浪费，另一方面无法明显提升人耳所能感知到的音质。

13.1.5　声道和立体声

我们在日常生活中会经常听到单声道、双声道这些专业词语，它们代表什么意思呢？

一个声道（Audio Channel）简单来讲就代表了一种独立的音频信号，所以双声道理论上就是两种独立音频信号的混合。具体而言，如果我们录制声音时在不同空间位置放置两套采集设备（或者一套设备多个采集头），就可以录制两个声道的音频数据了。后期对采集到的声音进行回放时，通过与录制时相同数量的外放扬声器来分别播放各声道的音频数据，就可以尽可能还原出录制现场的真实声音环境。

声道的数量发展经历了几个重要阶段，分别是：

- Monaural（单声道）

早期的音频录制是单声道的，它只记录一种音源，所以在处理上相对简单。播放时理论上也只要一个扬声器即可——即便有多个扬声器，它们的信号源也是一样的，达不到很好的效果。

- Stereophonic（立体声）

之所以称为立体声，是因为人们可以感受到声音所产生的空间感。大自然中的声音就是立体的，如办公室里键盘敲击声、马路上汽车鸣笛、人们的说话声等。那么，这些声音为什么会产生立体感呢？

我们知道，当“音源”发声后（比如在你的右前方有人在讲话），音频信号将分别先后到达人类的双耳。在这个场景中，是先传递到右耳然后左耳，并且右边的声音比左边稍强。这种细微的差别通过大脑处理后，人们就可以判断出声源的方位了。

这个简单的原理现在被应用到了多种场景。在音乐会的录制现场，如果我们只使用单声道采集，那么后期回放时所有的音乐器材都会从一个点出来；反之，如果能把现场各方位的声音单独记录下来，并在播放时模拟当时的场景，那么就可以营造出音乐会的逼真氛围。

为了加深读者的理解，我们特别从某双声道音频文件中提取出它的波形，如图13-4所示。

顺便以上面这个图为例再说一下音频的采样频率。我们把上图进行放大，如图13-5所示。

图中共有3个采样点，时间间隔是从4:26.790863到4:26.790908，即在大约0.000045秒的时间里采集了两个点，因而采样频率就是：

1/(0.000045/2)=44kHz，这和此音频文件所标记的采样率是一致的。

- 4.1 Surround Sound（4.1环绕立体声）

随着技术的发展和人们认知的提高，单纯的双声道已不能满足需求了。于是更多的声道数逐渐成为主流，其中被广泛采用的就有四声道环绕立体声。

其中的“4”代表了4个音源，位置分别是前左（Front-Left）、前右（Front-Right）、后左（Rear-Left）、后右（Rear-Right）。而小数点后面的1，则代表了一个低音喇叭（Subwoofer），专门用于加强低频信号效果。

▲图13-4　双声道音频文件

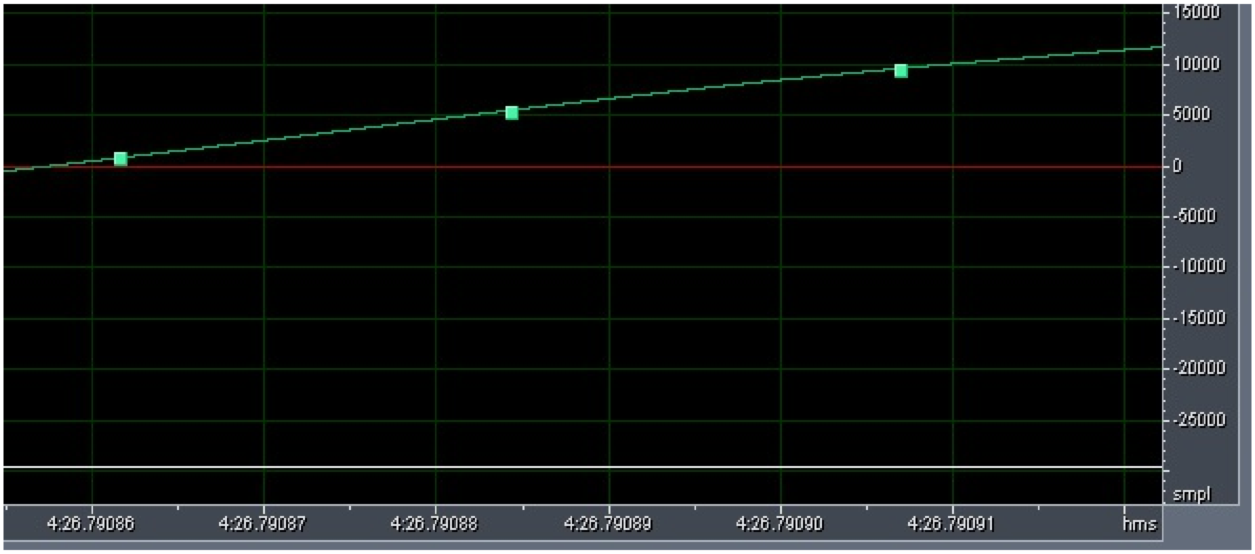

▲图13-5　采样频率实例

- 5.1 Surround Sound（5.1环绕立体声）

相信大家都听过杜比数字技术，这是众多5.1环绕声中的典型代表。另外，还有DTS，SDDS等都属于5.1技术。5.1相对于4.1多了一个声道，位置排列分别是前左、前右、中置（Center Channel）和两个Surround Channel，外加一个低音喇叭。

根据ITU（International Telecommunication Union）的建议，5.1环绕技术各扬声器位置如图13-6所示。

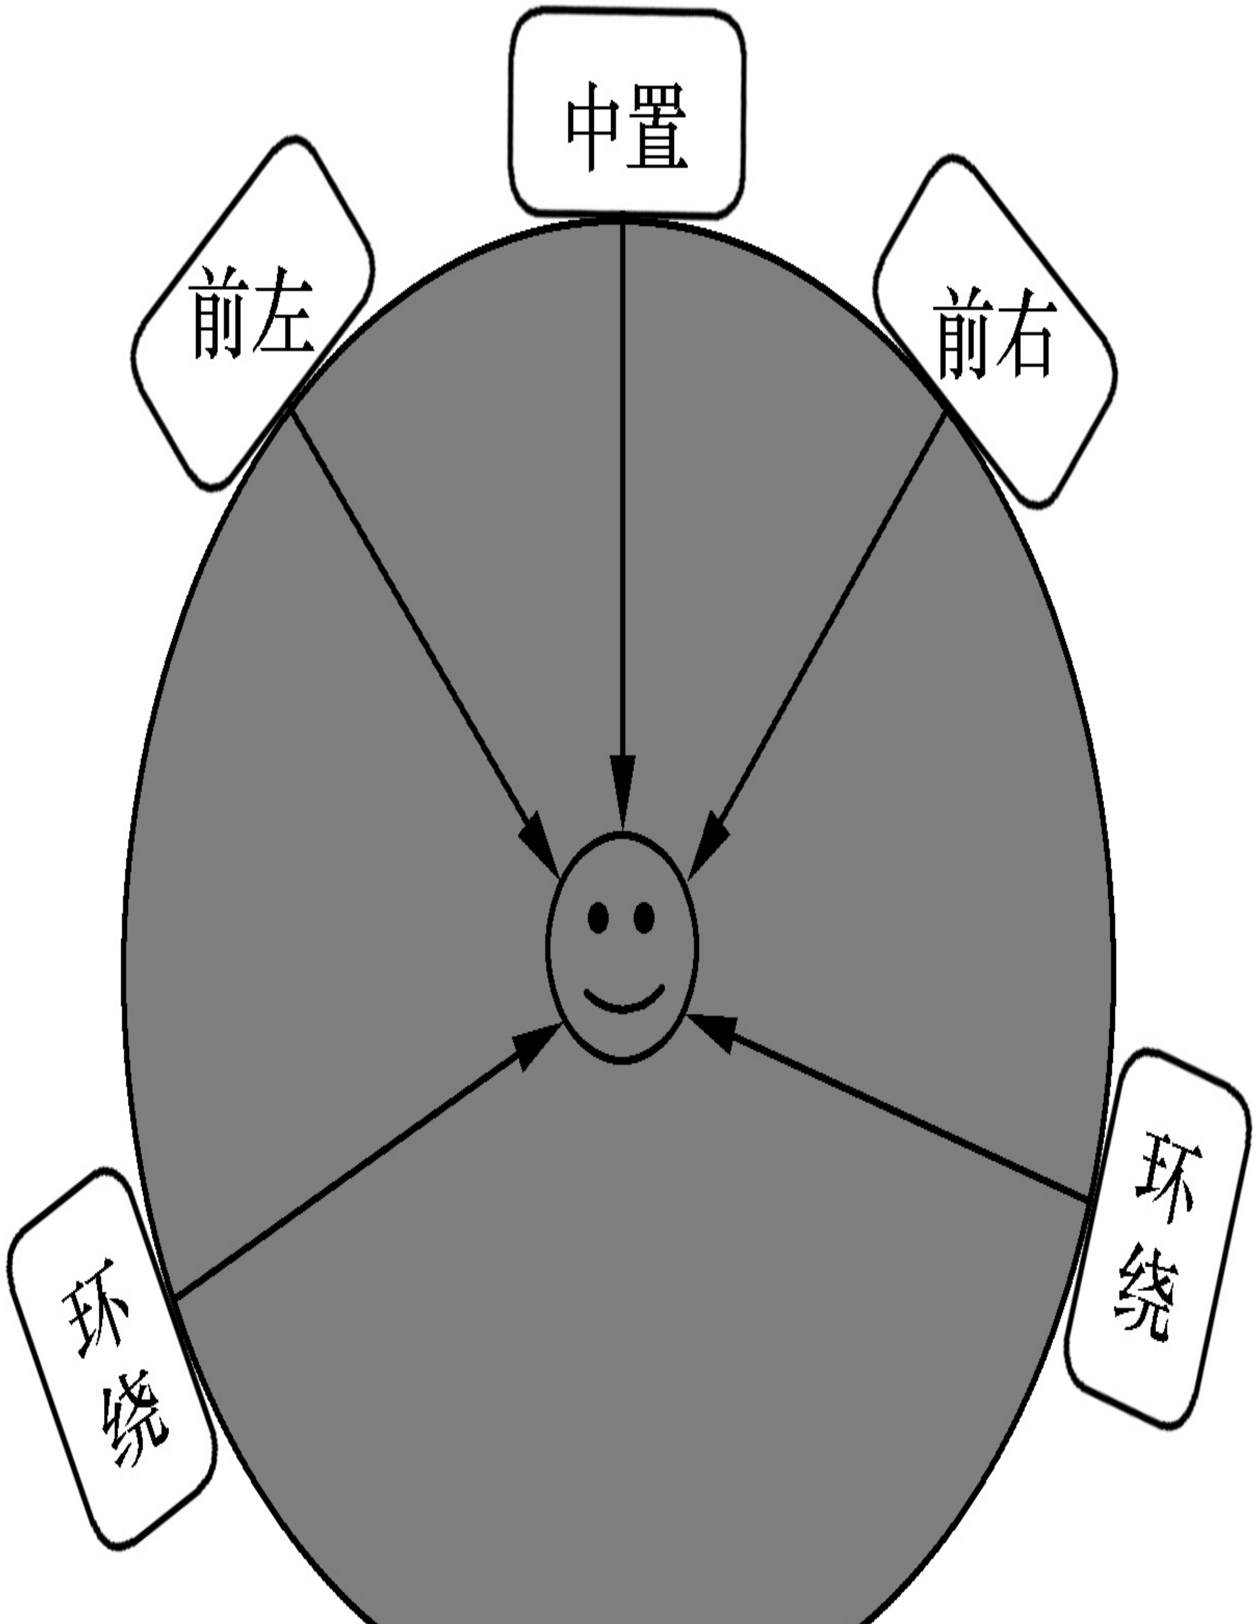
中置
前左
前右
环绕
环绕

▲图13-6 ITU发布的5.1环绕技术推荐方位图

从图13-6中可以得出。

- 各扬声器和听者距离是一致的，因而组成一个圆形。
- 角度分布：前左和前右分别是+22.5/22.5度（看电影时），以及+30//30度（听音乐时）；中置的角度总是为0；后面的两个环绕器分别为+110//110度。

13.1.6　声音定级——Weber－Fechner law

估计知道这个定律的人比较少，它是音频系统中计算声音大小的一个重要依据。严格来讲，它并不只适用于声音感知，而是人体各种感观（听觉、视觉、触觉）与刺激物理量之间的一条综合规律。其中心思想用公式表达就是：

$$\Delta I/I=C$$

其中ΔI表示差别阈值，I是原先的刺激量，而C则是常量。换句话说，就是能引起“感观变化”的刺激差别量与原先的刺激量比值是固定的。这样说可能比较抽象，我们举个例子来讲解下。

场合1. 去商店买一瓶水，原本2元钱的东西卖到了5元钱。

场合2. 买一辆奔驰车，原先价格是一百万元，现在涨了3元钱。

上述两种场合下，前后的商品价格差虽然都只有3元，但对我们造成的主观感受是有很大不同的。显然在第一种情况下，我们会觉得这瓶水很贵而可能选择不买；而后一种情况则对我们基本不会产生任何影响。这是因为引起“感官变化”的刺激量并不仅仅取决于前后变化量的绝对差值，同时也与原来的刺激量有很大关系。对于特定的场合，上述公式中的C值是固定的。比如有的人觉得2元钱的东西卖3元就是贵了，有的人则能接受2元钱的东西卖4元，不同的人对于C值是会有差异的。

这就是德国心理物理学家Ernst Heinrich Weber发现的规律，后来他的学生Gustav Fechner把这一发现用公式系统地表达了出来，就是上面的韦伯定律。

再后来，Fechner在此基础上又做了改进。他提出刺激量和感知是呈对数关系的，即当刺激强度以几何级数增长时，感知强度则以算术级数增加。这就是Weber–Fechner Law，公式如下：

$$S = C \log R$$

那么，这对音频系统有什么指导意义呢？

我们知道，系统音量是可调的，如分为0～20个等级。这些等级又分别对应不同的输出电平值，那么我们如何确定每一个等级下应该设置的具体电平值呢？你可能会想到平均分配。没错，这的确是一种方法，只不过按照这样的算法所输出的音频效果在用户听来并不是最佳的——因为声音的变化不连续。

一个更好的方案就是遵循Weber–Fechner Law，即采用对数的方式。在Android系统中，这一部分计算过程对应的具体实现代码在audiosystem.cpp文件中，有兴趣的读者可以自行阅读了解。

13.1.7 音频文件格式

前面小节的内容分析了音频采样的基本过程，它将连续的声音波形转换成若干范围内的离散数值，从而将音频数据以二进制的形式在计算机系统中表示出来。不过音频的处理并没有结束，我们通常还需要对上述过程产生的数据进行格式转化，然后才最终存储到设备中。

要特别注意文件格式（File Format）和文件编码器（Codec）的区别。编码器负责对原始数据进行一定的前期处理，如采用压缩算法以减小体积，然后才以某种特定的文件格式进行保存。Codec和File Format不一定是一对一的关系，如常见的AVI就支持多种音频和视频编码方式。

理论上可以把数字音频格式分为以下几类。

- 不压缩的格式（UnCompressed Audio Format）

比如前面所提到的PCM数据，就是采样后得到的未经压缩的数据。PCM数据在Windows和Mac系统上通常分别以wav和aiff后缀名进行存储。可想而知，由此产生的文件大小是比较可观的。

- 无损压缩格式（Lossless Compressed Audio Format）

这种压缩的前提是不破坏音频信息，即后期可以完整地还原出原始数据；同时它在一定程度上可以减小文件体积。目前已有多种实现，如FLAC，APE(Monkey’s Audio)，WV(WavPack)，m4a(Apple Lossless)等。

- 有损压缩格式（Lossy Compressed Audio Format）

无损压缩技术能减小的文件体积相对有限，因而在满足一定音质要求的情况下，我们还可以进行有损压缩。其中，最为人所熟知的当然是MP3格式以及iTunes上使用的AAC。通常这些格式都可以指定压缩的比率——比率越大，文件体积越小，但效果也越差。

至于采用哪一种格式，大家要视具体的使用场景而定，并没有固定的答案。

13.2 音频框架

Android的音频系统在很长一段时间内都是外界诟病的焦点。的确，早期的Android系统在音频处理上相比于iOS有一定的差距，这也是很多专业的音乐播放软件开发商没有推出Android平台产品的一个重要原因。但这并不代表它的音频框架一无是处，基于Linux系统的Android平台却有很多值得我们学习的地方。

13.2.1 Linux中的音频框架

在计算机发展的早期，电脑的声音处理设备是由一个非常简易的LoudSpeaker外加发声器（Tone Generator）构成的，功能相对局限。后来人们想到了以Plug-in的形式来扩展音频设备，“Sound Blaster”就是其中很有名的一个。这种早期的声卡以插件方式连接到电脑主板上，并提供了各种复杂的音频设备。但是，独立的硬件设计也意味着成本的增加，于是随着技术的发展又出现了“板载声卡”，即我们俗称的“集成声卡”。“板载声卡”又分为“软声卡”和“硬声卡”——如果声卡本身没有“主处理”芯片，而只有解码芯片，需要通过CPU运算来执行处理工作，那么就是“软声卡”；反之就是“硬声卡”。通常面向低端市场的计算机都会包含一个集成的声卡设备以降低成本。

一个典型的声卡通常包含3个部分。

- Connectors

用于声卡与外放设备，如扬声器、耳机的连接，又被称为“jacks”。

- Audio Circuits

声卡的主要实现体，负责信号的放大、混音以及模拟数字信号转换等操作。

- Interface

连接声卡与计算机总线的单元，如PCI总线。

我们可以通过“cat /proc/asound/cards”命令来查看计算机中安装的声卡设备，如范例所示。

```
0 [I82801AAICH    ]: ICH - Intel 82801AA-ICH
                      Intel 82801AA-ICH with STAC9700,83,84 at irq 21
```

目前市面上声卡的种类众多，既有复杂的高性能的，也有低端的简易的。那么对于一个操作系统来说，它如何管理这些音频设备并向上层应用提供统一的接口呢？

Android严格来讲只是一个Linux系统，它依赖于内核提供的各种驱动支持，其中自然也包括音频驱动。因此，我们有必要先花点时间来学习下Linux平台下两种主要的音频驱动架构。

- OSS (Open Sound System)

早期Linux版本采用的是OSS框架，它也是UNIX及类UNIX系统中广泛使用的一种音频体系。OSS既可以指OSS接口本身，也可以用来表示接口的实现。OSS的作者是Hannu Savolainen，就职于4Front Technologies公司。由于涉及知识产权问题，OSS后期的支持与升级不是很好，这也是Linux内核最终放弃OSS的一个重要原因。

另外，OSS在某些方面也遭到了人们的质疑。比如：

对音频新特性的支持不足；

缺乏对最新内核特性的支持等。

当然，OSS作为UNIX下音频系统的早期实现，本身算是比较成功的。它符合“一切都是文件”的设计理念，而且作为一种体系框架，其更多地只是规定了应用程序与操作系统音频驱动之间的交互，这给各厂商进行产品定制开发提供了很多灵活性。总的来说，OSS使用了如表13-1所示的设备节点。

表13-1　OSS采用的设备节点

设备节点	说　明

/dev/dsp	向此文件写数据→输出到外放Speaker 向此文件读数据→通过Microphone进行录音
/dev/mixer	混音器，用于对音频设备进行相关设置，如音量调节
/dev/midi00	第一个MIDI端口，还有midi01，midi02等
/dev/sequencer	用于访问合成器（synthesizer），常用于游戏音效的产生

更多详情可以参考OSS的官方说明。

- ALSA(Advanced Linux Sound Architecture)

ALSA是Linux社区为了取代OSS而提出的一种框架，是一个源代码完全开放的系统（遵循GNU GPL和GNU LGPL）。ALSA在Kernel 2.5版本中被正式引入后，OSS就逐步被排除在内核之外。当然，OSS本身还是在不断维护的，只是不再为Kernel所采用而已。

ALSA相对于OSS提供了更多也更为复杂的API接口，因而开发难度相对来说比较大。为此，ALSA专门提供了一个供开发者使用的工具库，以帮助他们更好地利用ALSA的API。根据官方文档的介绍，ALSA有如下特性。

- 高效地支持大多数类型的Audio Interface（不论是消费型还是专业型的多声道声卡）。
- 高度模块化的声音驱动。
- SMP及线程安全（Thread-Safe）设计。
- 在用户空间提供了alsa-lib来简化应用程序的编写。

- 与OSS API保持兼容，这样可以保证老的OSS程序在系统中能正常运行。

ALSA主要由表13-2所示的几个部分组成。

表13-2 Alsa-Project Package

Element	Description
alsa-driver	内核驱动包
alsa-lib	用户空间的函数库
alsa-utils	包含了很多实用的小程序，如alsactl：用于保存设备配置amixer：是一个命令行程序，用于音量和其他声音控制alsamixer：amixer的ncurses版acconnect和aseqview：用于制作MIDI连接以及检查已连接的端口列表aplay和arecord：两个命令行程序，分别用于播放和录制多种格式的音频
alsa-tools	包含一系列工具程序
alsa-firmware	音频固件支持包
alsa-plugins	插件包，如jack，pulse，maemo

alsa-oss	用于兼容OSS的模拟包
pyalsa	用于编译Python版本的alsa lib

Alsa主要的文件节点如下：

（1）Information Interface（/proc/asound）；

（2）Control Interface（/dev/snd/controlCX）；

（3）Mixer Interface（/dev/snd/mixerCXDX）；

（4）PCM Interface（/dev/snd/pcmCXDX）；

（5）Raw MIDI Interface（/dev/snd/midiCXDX）；

（6）Sequencer Interface（/dev/snd/seq）；

（7）Timer Interface（/dev/snd/timer）。

关于ALSA的更多知识，建议读者自行参阅相关文档，这对于后续理解Android中的Audio系统架构大有裨益。

13.2.2 TinyAlsa

看到“Tiny”这个词，大家应该能猜到这是一个ALSA的缩减版本。实际上在Android系统的其他地方也可以看到类似的做法——因为我们既想用开源项目，又担心工程太大太烦琐，怎么办？那就只能瘦身，于是很多Tiny-XXX就出现了。

早期版本中，Android系统的音频架构主要是基于ALSA的，其上层实现可以看作ALSA的一种“应用”。后来可能是由于ALSA所存在的一些不足，Android系统开始不再依赖于ALSA提供的用户空间层的实现。这也是我们在它的库文件夹中逐渐找不到alsa相关lib的原因，如图13-7所示。

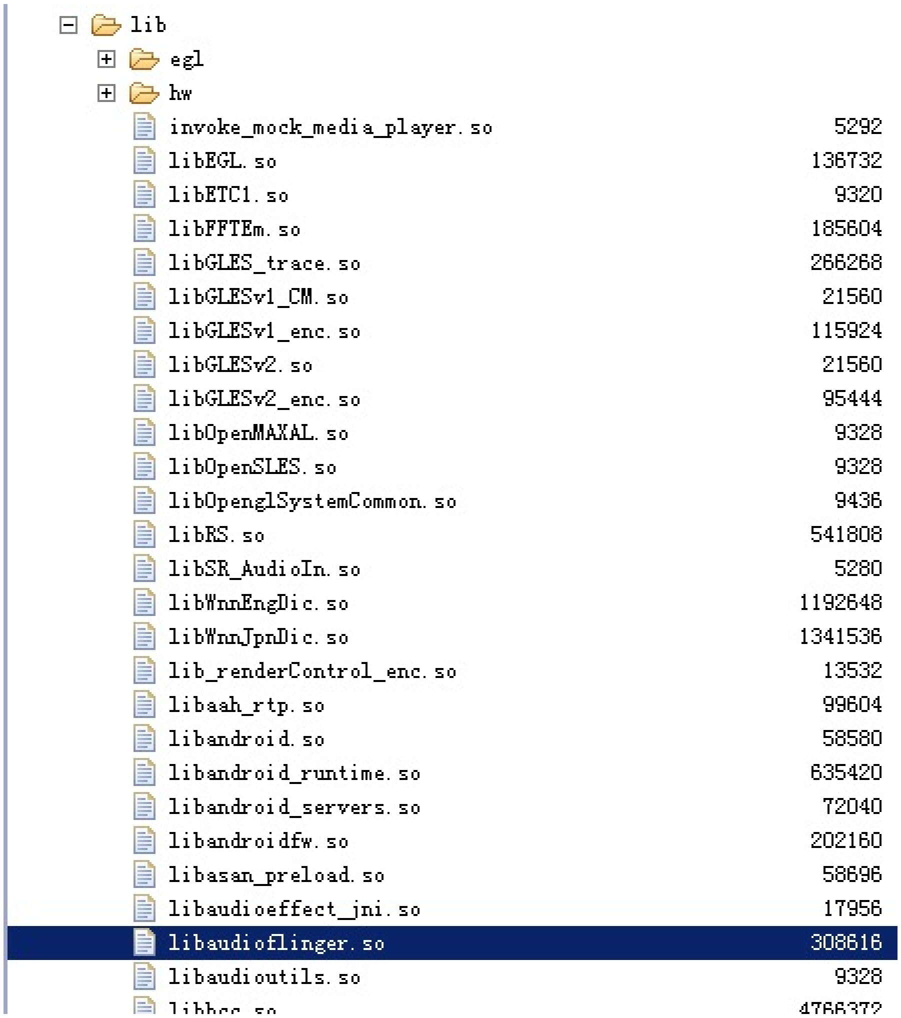
lib
egl
hw
invoke_mock_media_player.so 5292
libEGL.so 136732
libETC1.so 9320
libFFTEm.so 185604
libGLES_trace.so 266268
libGLESv1_CM.so 21560
libGLESv1_enc.so 115924
libGLESv2.so 21560
libGLESv2_enc.so 95444
libOpenMAXAL.so 9328
libOpenSLES.so 9328
libOpenglSystemCommon.so 9436
libRS.so 541808
libSR_AudioIn.so 5280
libWnnEngDic.so 1192648
libWnnJpnDic.so 1341536
lib_renderControl_enc.so 13532
libaah_rtp.so 99604
libandroid.so 58580
libandroid_runtime.so 635420
libandroid_servers.so 72040
libandroidfw.so 202160
libasan_preload.so 58696
libaudioeffect_jni.so 17956
libaudioflinger.so 308616
libaudioutils.so 9328

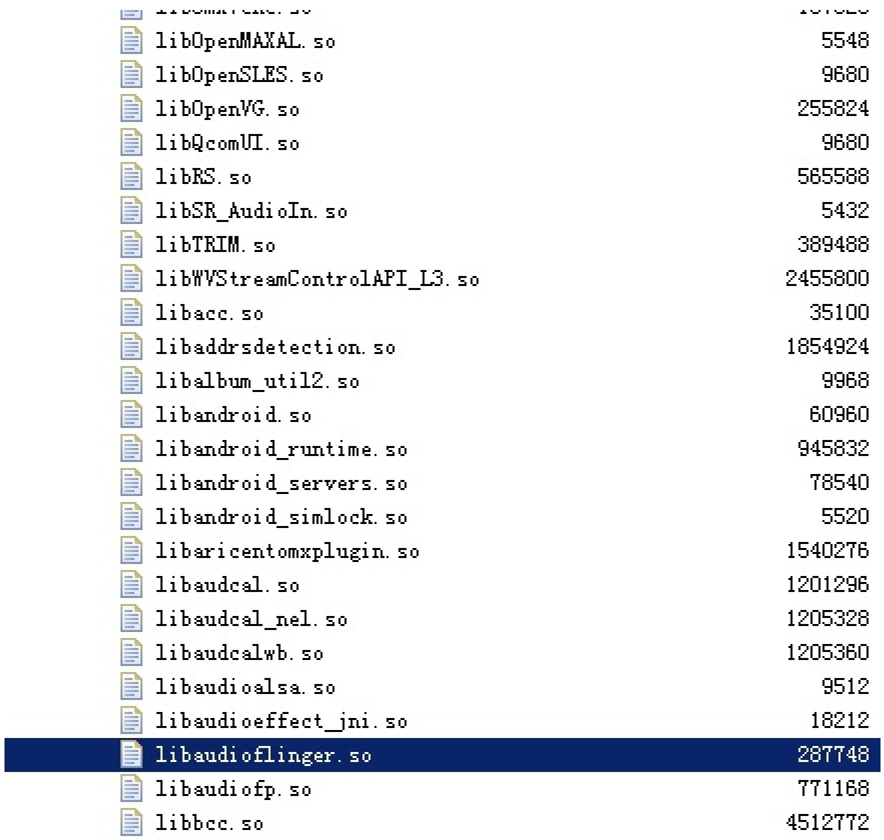

▲图13-7　Android新老版本在音频库上的区别

而取代它的是tinyalsa相关的库文件，如图13-8所示。

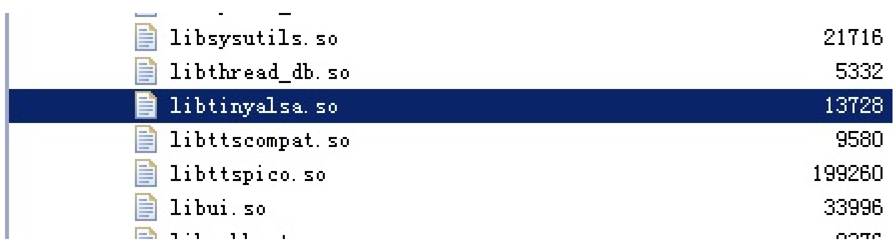

▲图13-8 Tinyalsa取代Alsa-lib

同时我们可以看到，externl目录下多了一个“tinyalsa”文件夹，其中包含了为数不多的几个源码文件，如表13-3所示。

表13-3　Tiny-alsa工程文件

Source File	Description

Android.mk	makefile
mixer.c	Mixer Interface实现
pcm.c	PCM Interface实现
tinycap.c	Caputer工具
tinymix.c	Mixer工具
tinyplay.c	Play工具
include/tinyalsa/asoundlib.h	头文件

可见TinyAlsa与原版Alsa的差异还是相当大的，它只是部分支持了其中的两种Interface。而像Raw MIDI、Sequencer、Timer等Interface则没有涉及——当然这对于一般的嵌入式设备来说还是足够了。

TinyAlsa作为Alsa-lib的一个替代品，自面世以来得到的公众评价有褒有贬，不能一概而论——对于厂商来说，适合自己的就是最好的；而且各厂商也可以在此基础上扩展自己的功能，真正地把ALSA应用到极致。

13.2.3 Android系统中的音频框架

一个好的系统架构需要尽可能地降低上层实现与具体硬件设备的耦合——这其实是操作系统的设计目标之一，当然也同样适用于音频系统。音频系统的雏形框架可以简单地用图13-9来表示。

在简图中，除去Linux本身的Audio驱动外，整个Android音频体系都被看成了User。因而我们可以认为Audio Driver就是上层用户与硬件间的“隔离板”。但是如果单纯采用上图所示的框架来设计音频系统，对于使用音频功能的上层应用则是个不小的负担。显然“绝顶聪明”的Android开发团队还会进一步细化“User”部分。

细化的依据自然还是Android的几个层次结构，包括应用层、framework层、库层和HAL层，如图13-10所示。

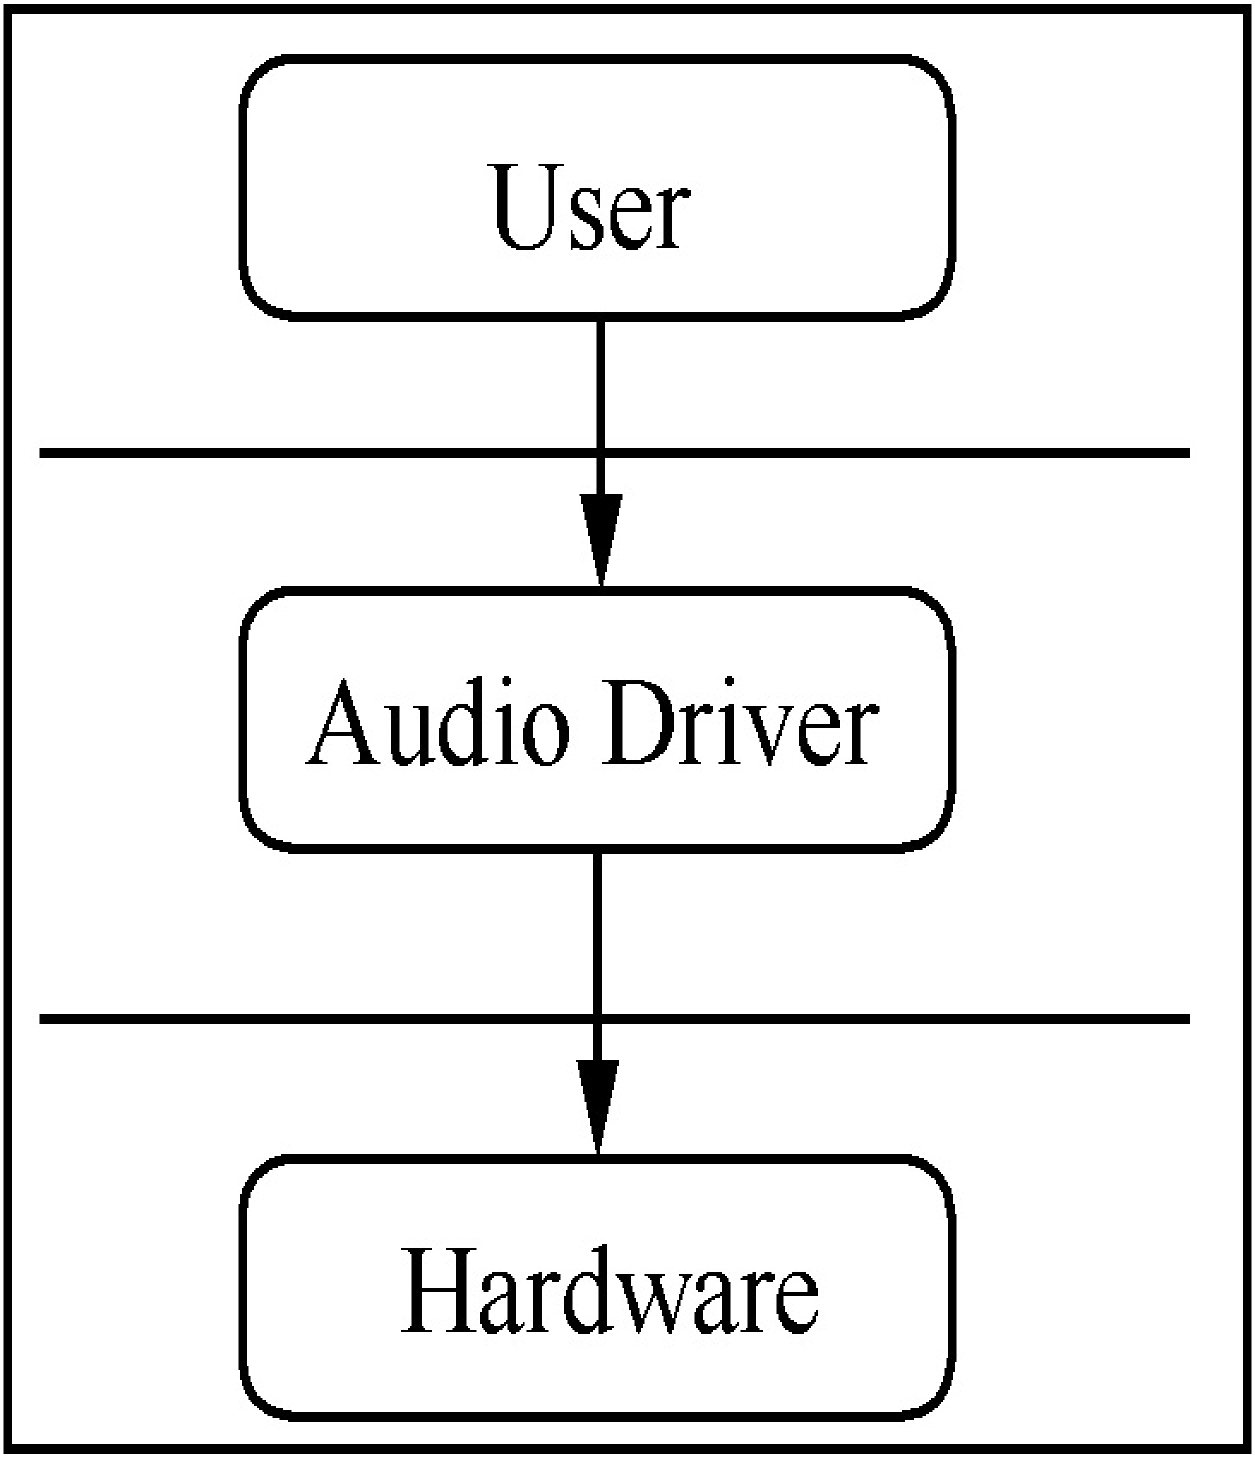

▲图13-9　音频系统的雏形框架图

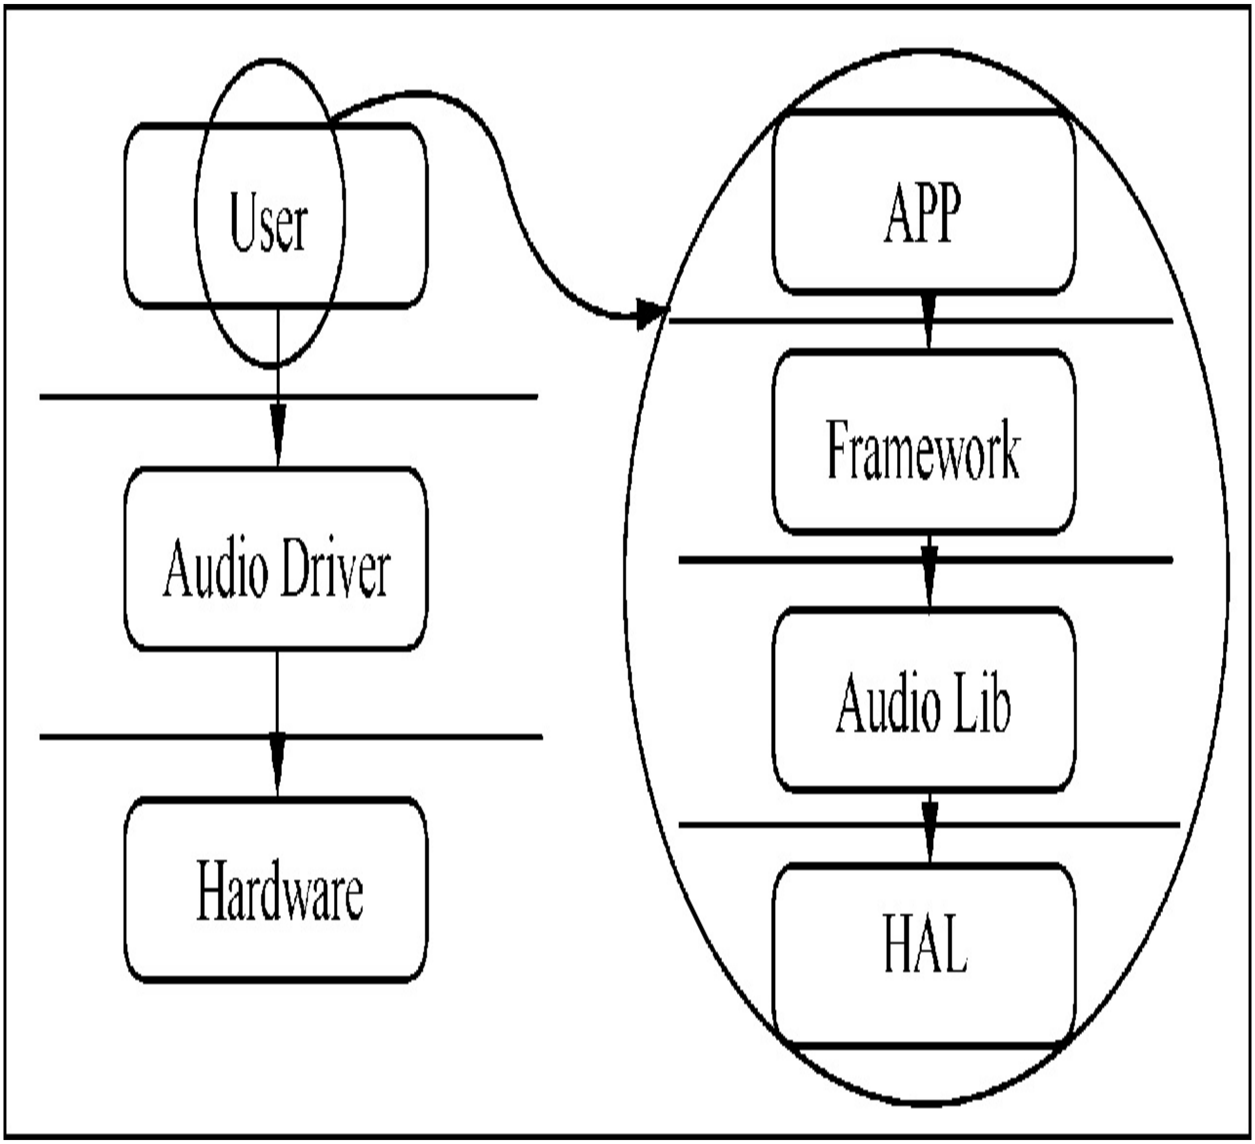

▲图13-10　音频框架在Android系统中的进一步细化

我们可以结合目前已经学习过的知识，思考一下图13-10中每一个层次所需要完成的任务（先不考虑蓝牙音频部分）。

1．APP

这是整个音频体系的最上层。比如厂商根据特定需求写的一个音乐播放器；游戏中的音效控制；或者调节音频属性的应用软件等。

2．Framework

相信读者可以立即想到MediaPlayer和MediaRecorder，因为这是我们在开发音频相关产品时使用最广泛的两个类。另外，Android系统中还有另外两个专门用于音频管理的类，即AudioTrack和AudioRecorder——MediaPlayerService内部的音频实现其实就是通过它们来完成的。我们后面还会有详细介绍。

除此之外，Android系统还为我们控制音频系统提供了AudioManager、AudioService及AudioSystem类。这些都是framework层面向应用开发者设计的封装实现。

3．Libraries

我们知道，Framework层的很多Java类实际上只是APK应用程序与Android库文件的“中介”而已。因为上层应用程序采用Java语言编写，它们需要最直接的Java接口的支持，这也是Framework层存在的意义之一。而作为“中介”，它们并不会真正去实现或者说只实现了其中的一小部分功能——真正的“主角”隐藏在底层库中。

需要特别说明的是，Android系统中与音频相关的库有很多。

比如上面的AudioTrack、AudioRecorder、MediaPlayer和MediaRecorder等在底层库中都能找到相对应的类（这部分库的源码集中放置在工程的frameworks/av/media/libmedia中，多数是以C++语言编写的）。

除了上面各种类库的实现外，音频系统还需要一个“核心中控”。或者更通俗地说，需要一个系统服务（类似于WindowManagerService、LocationManagerService、ActivityManagerService等），这就是AudioFlinger和AudioPolicyService。它们的源码放置在frameworks/av/services/audioflinger目录中，生成的最主要的库名叫作libaudioflinger。

音频体系中另一个重要的系统服务是MediaPlayerService，它的位置在frameworks/av/media/ libmediaplayerservice中。

因为涉及的库和相关类很多，建议读者在学习的时候分为两条线索。

其一，以“库”为线索。比如AudioPolicyService和AudioFlinger都封装在libaudioflinger库中；而AudioTrack，AudioRecorder等一系列实现则在libmedia库中。

其二，以“进程”为线索。“库”并不代表一个进程，进程则依赖于库来运行。虽然有的类是在同一个库中实现的，但并不代表它们会在同一个进程中被调用。比如AudioFlinger和AudioPolicyService都驻留于名为mediaserver的系统进程中；而AudioTrack/AudioRecorder和MediaPlayer/MediaRecorder一样实际上只是应用进程的一部分，它们通过Binder服务来与其他系统进程通信。

在源码分析的过程中，一定要紧抓住这两条线索，才不至于“迷失方向”。

4．HAL

从设计层面来看，音频的硬件抽象层的服务对象是AudioFlinger。这一方面说明了AudioFlinger可以不用直接调用底层的音频驱动；另一方面AudioFlinger的上层（包括和它同一层的MediaPlayerService）模块只需要与它进行通信就可以实现音频相关的功能了。因而我们可以认为AudioFlinger才是Android音频系统中真正的“隔离板”——无论下面如何变化，上层的实现都可以保持兼容。

音频方面的硬件抽象层主要分为两个核心，即AudioFlinger和AudioPolicyService。实际上后者（Policy）并不是一个真实的设备，只是采用虚拟设备的方式来让厂商可以方便地定制出自己的“音频策略”。

抽象层的任务是将AudioFlinger/AudioPolicyService真正地与硬件设备关联起来，但又必须提供灵活的结构来应对变化——特别是对于Android这个更新相当频繁的系统。比如早期Android系统中的Audio体系依赖于内核的ALSA-lib，后来就变为了tinyalsa，这样的转变不应该也不允许对上层造成“破坏”。因而Audio HAL提供了统一的接口来定义它与AudioFlinger/AudioPolicy Service之间的通信方式，这就是audio_hw_device、audio_stream_in及audio_stream_out等结构体存在的目的。这些Struct数据类型内部大多只包含了对函数指针的定义，或者说是一些“壳”。当AudioFlinger/AudioPolicyService初始化时，它们会去寻找系统中最匹配的实现（这些实现驻留在以

audio.primary.*及audio.a2dp.*为名的各种库中）来填充这些“壳”。

根据具体产品的不同，音频设备存在很大差异。在Android的音频架构中，这些差异问题都是由HAL层的audio.primary等库来解决的，而不需要大规模地修改上层实现。

基于上面的分析，我们给出一个完整的Android音频系统框架供读者参考（没有列出Linux层的实现，如ALSA Driver等），如图13-11所示。

本章剩余小节将分别介绍上述框架图里的几个重点模块，包括AudioFlinger、AudioTrack/ AudioRecorder、AudioManager/AudioPolicyService，并简单地介绍音频上层建筑中的一些核心模块如MediaPlayerService等。

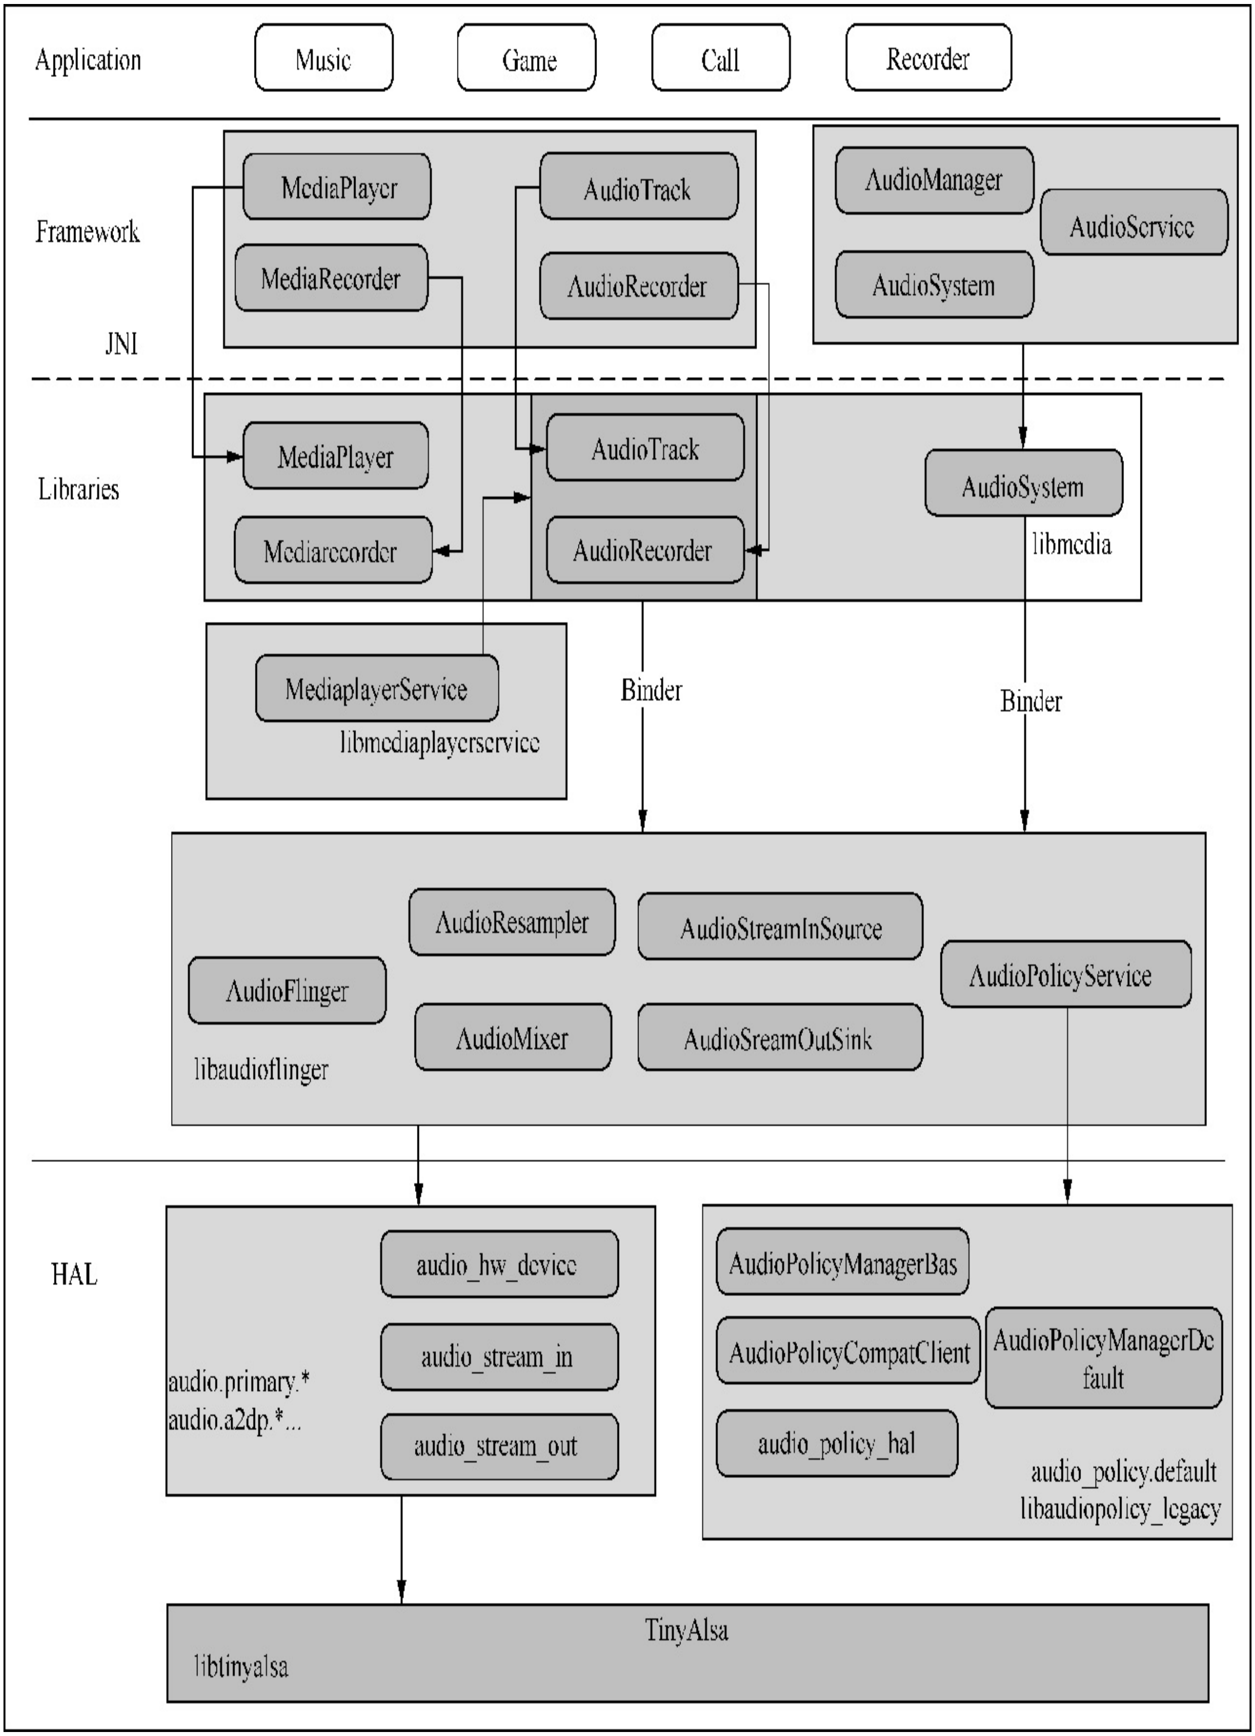

Application
Music
Game
Call
Recorder
Framework
MediaPlayer
MediaRecorder
AudioTrack
AudioRecorder
AudioManager
AudioService
AudioSystem
JNI
Libraries
MediaPlayer
Mediarecorder
AudioTrack
AudioRecorder
AudioSystem
libmedia
MediaplayerService
libmediaplayerservice
Binder
Binder
AudioResampler
AudioStreamInSource
AudioFlinger
AudioPolicyService
AudioMixer
AudioSreamOutSink
libaudioflinger
HAL
audio_hw_device
audio_stream_in
audio_stream_out
audio.primary.*
audio.a2dp.*...
AudioPolicyManagerBas
AudioPolicyCompatClient
AudioPolicyManagerDe fault
audio_policy_hal
audio_policy.default
libaudiopolicy_legacy
TinyAlsa
libtinyalsa

▲图13-11　Android音频系统框架全图

13.3　音频系统的核心——AudioFlinger

在上面的框架图中，我们可以看到AudioFlinger（下面简称AF）是整个音频系统的核心与难点。作为Android系统的音频中枢，它同时也是一个系统服务，起到承上（为上层提供访问和管理音频的接口）启下（通过HAL来管理音频设备）的作用。只有理解了AudioFlinger，才能以此为基础扩展深入其他模块的学习中，因而我们把它放在前面分析。

13.3.1　AudioFlinger服务的启动和运行

我们知道，Android中的系统服务分为两类，分别是Java层和Native层的System Services。其中AudioFlinger和SurfaceFlinger一样，都属于后者。Java层服务通常在SystemServer.java中启动，如后面即将看到的AudioService就属于这种情况；而Native层服务则通常是各服务方按照自己的部署来决定何时启动以及如何启动的。例如AudioFlinger就是利用一个Linux程序来间接创建的，如下所示：

```
/*frameworks/av/media/mediaserver/Main_mediaserver.cpp*/
int main(int argc, char** argv)
{…//4.3版本中考虑了MediaLogService，但不影响我们的分析，可以直接略过
    sp<ProcessState> proc(ProcessState::self());
    sp<IServiceManager> sm = defaultServiceManager();
    ALOGI("ServiceManager: %p", sm.get());
    AudioFlinger::instantiate();
    MediaPlayerService::instantiate();
    CameraService::instantiate();
    AudioPolicyService::instantiate();
    registerExtensions();
    ProcessState::self()->startThreadPool();
    IPCThreadState::self()->joinThreadPool();
}
```

这个mediaserver的目录下只有少数几个文件。它的任务很简单，就是把所有媒体相关的native层服务（包括AudioFlinger，MediaPlayerService，CameraService和AudioPolicyService）启动起来。可以参考其Android.mk：

```
LOCAL_SRC_FILES:= \
     main_mediaserver.cpp
```

```
LOCAL_SHARED_LIBRARIES := \
     libaudioflinger \
     libcameraservice \
     libmedialogservice \
     libcutils \
     libnbaio \
     libmedia \
     libmediaplayerservice \
…
LOCAL_MODULE:= mediaserver
```

根据前面的分析，AudioFlinger的源码实现是放在libaudioflinger库中的，因而在编译mediaserver时要引用这个库，其他服务也是类似的做法。编译生成的mediaserver可执行文件将被烧录到设备的/system/bin/mediaserver路径中，然后当系统开机时由init进程启动，其在Init.rc中的对应配置是：

```
service media /system/bin/mediaserver
    class main
    user media
    group audio camera inet net_bt net_bt_admin net_bw_acct drmrp
    ioprio rt 4
```

值得一提的是，AudioFlinger::instantiate()并不属于AudioFlinger内部的静态函数，而是BinderService类的一个实现。包括AudioFlinger，AudioPolicyService等在内的几个服务都继承自这个统一的Binder服务类。比如：

```
class AudioFlinger :
    public BinderService<AudioFlinger>,
    public BnAudioFlinger…
```

从名称上看，BinderService应该是实现了Binder跨进程通信相关的一些功能。实际上它是一个模板类，其中的函数instantiate用于把模板中指定的服务创建出来，并添加到ServiceManager中：

```
/*frameworks/native/include/binder/BinderService.h*/
    template<typename SERVICE> …
    static status_t publish(bool allowIsolated = false) {
        sp<IServiceManager> sm(defaultServiceManager());
        return sm->addService(String16(SERVICE::getServiceName())
    }
    static void instantiate() { publish(); } //调用publish
```

回头看看AudioFlinger的构造函数，发现它只是简单地为内部一些变量做了初始化，除此之外就没有任何有效的代码了（其他部分源码与log和debug有关，可以忽略不计）：

```
AudioFlinger::AudioFlinger()
    :BnAudioFlinger(),mPrimaryHardwareDev(NULL), mHardwareStatus(
      mMasterVolume(1.0f), mMasterMute(false), mNextUniqueId(1),
      mMode(AUDIO_MODE_INVALID),mBtNrecIsOff(false){…
}
```

读者可能会觉得疑惑，即AudioFlinger在什么情况下会开始执行实际的工作呢？没错，是在onFirstRef()中。BnAudioFlinger是由RefBase层层继承而来的，并且IServiceManager::addService的第二个参数实际上是一个强指针引用（const sp<IBinder>&），因而AudioFlinger具备了“强指针被第一次引用时调用onFirstRef”的程序逻辑。如果读者不是很清楚这些细节，可以参考下本书的强指针章节，这里不再赘述：

```
void AudioFlinger::onFirstRef()
{
    int rc = 0;
    Mutex::Autolock _l(mLock);
    char val_str[PROPERTY_VALUE_MAX] = { 0 };
    if (property_get("ro.audio.flinger_standbytime_ms", val_str,
        uint32_t int_val;
        if (1 == sscanf(val_str, "%u", &int_val)) {
            mStandbyTimeInNsecs = milliseconds(int_val);
            ALOGI("Using %u mSec as standby time.", int_val);
        } else {
            mStandbyTimeInNsecs = kDefaultStandbyTimeInNsecs;
            …
        }
    }
    mMode = AUDIO_MODE_NORMAL;
}
```

属性ro.audio.flinger_standbytime_ms为用户调整standby时间提供了一个接口，早期版本中这个时间值是固定的。接下来程序会初始化几个重要的内部变量——和前面AudioFlinger构造函数中的做法不同的是，这里赋予各变量的都是有效的值。

从这时开始，AudioFlinger就是一个“有意义”的实体了。接下来其他进程可以通过Service Manager来访问AudioFlinger，并调用

createTrack，openOutput等一系列接口来驱使AudioFlinger执行音频处理操作，我们在后续小节会做详细讲解。

13.3.2 AudioFlinger对音频设备的管理

虽然AudioFlinger实体已经成功创建并初始化，但到目前为止它还没有涉及具体的工作。

从职能分布上来讲，AudioPolicyService是策略的制定者，如什么时候打开音频接口设备、某种Stream类型的音频对应什么设备等都由其决定。而AudioFlinger则是策略的执行者，如具体如何与音频设备进行通信、如何维护现有系统中的音频设备以及多个音频流的“混音”如何处理等都得由它来完成。

目前Audio系统中支持的音频设备接口（Audio Interface）分为3大类，即：

```
/*frameworks/av/services/audioflinger/AudioFlinger.cpp*/
static const char * const audio_interfaces[] = {
    AUDIO_HARDWARE_MODULE_ID_PRIMARY, //主音频设备，必须存在
    AUDIO_HARDWARE_MODULE_ID_A2DP,//蓝牙A2DP音频
    AUDIO_HARDWARE_MODULE_ID_USB, //USB音频，早期的版本不支持
};
```

每种音频设备接口由一个对应的“so库”来提供支持。那么AudioFlinger怎么会知道当前设备中支持上述的哪些接口，每种接口又支持哪些具体的音频设备呢？这是AudioPolicyService的责任之一，即根据用户配置来指导AudioFlinger加载设备接口。

当AudioPolicyManagerBase（AudioPolicyService中持有的Policy管理者，后面小节有详细介绍）构造时，它会读取厂商关于音频设备的描述文件（audio_policy.conf），然后据此来打开以上3类音频接口（如果存在的话）。这一过程最终会调用loadHwModule@AudioFlinger，如下所示：

```
/*frameworks/av/services/audioflinger*/
audio_module_handle_t AudioFlinger::loadHwModule(const char *name
interfaces数组成员中的字符串*/
{
    if (!settingsAllowed()) {
        return 0;
```

```
    }
    Mutex::Autolock _l(mLock);
    return loadHwModule_l(name);
}
```

这个函数没有做实质性的工作，只是执行了加锁动作，然后接着调用下面的函数：

```
audio_module_handle_t AudioFlinger::loadHwModule_l(const char *na
{
      /*Step 1. 是否已经添加过这个interface?*/
    for (size_t i = 0; i < mAudioHwDevs.size(); i++) {
        if (strncmp(mAudioHwDevs.valueAt(i)->moduleName(), name,
            ALOGW("loadHwModule() module %s already loaded", name
            return mAudioHwDevs.keyAt(i);
        }
    }
        /*Step 2. 加载audio interface*/
    audio_hw_device_t *dev;
    int rc = load_audio_interface(name, &dev);
    …
    /*Step 3. 初始化*/
    mHardwareStatus = AUDIO_HW_INIT;
    rc = dev->init_check(dev);
    mHardwareStatus = AUDIO_HW_IDLE;
    …
    /*Step 4. 添加到全局变量中*/
    audio_module_handle_t handle = nextUniqueId();
    mAudioHwDevs.add(handle, new AudioHwDevice(name, dev,flags));

    return handle;
}
```

Step1@loadHwModule_l。首先查找mAudioHwDevs中是否已经添加了变量name所指示的audio interface，如果是就直接返回。第一次进入时mAudioHwDevs的size为0，所以还会继续往下执行。

Step2@ loadHwModule_l。加载指定的audio interface，如“primary”“a2dp”或者“usb”。函数load_audio_interface用来加载设备所需的库文件，然后打开设备并创建一个audio_hw_device_t实例。音频接口设备所对应的库文件名称是有一定格式的，如a2dp的模块名可能是audio.a2dp.so或者audio.a2dp.default.so等。查找路径主要有两个，即：

```
/** Base path of the hal modules */
#define HAL_LIBRARY_PATH1 "/system/lib/hw"
#define HAL_LIBRARY_PATH2 "/vendor/lib/hw"
```

当然，因为Android是完全开源的，各开发商可以根据自己的需求来进行相应的修改。比如下面是某手机设备的音频库截图，如图13-12所示。

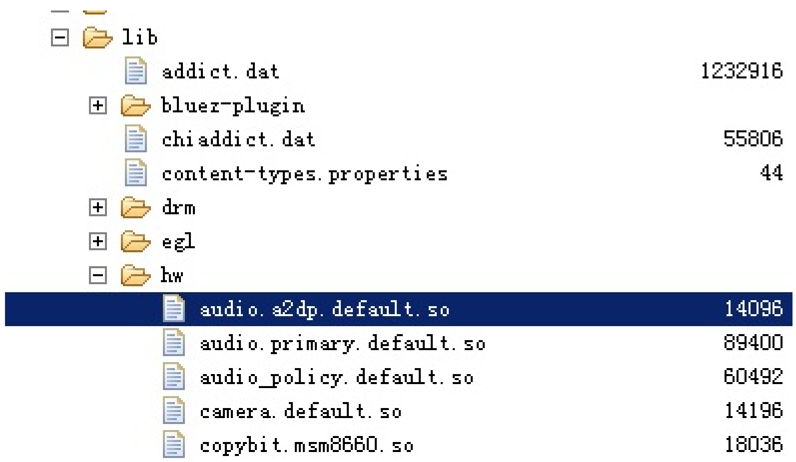

▲图13-12 音频库实例

Step3@ loadHwModule_l。进行初始化操作。其中init_check是为了确定这个audio interface是否已经成功初始化，0是成功，其他值表示失败。接下来如果这个device支持主音量，我们还需要通过set_master_volume进行设置。应该特别注意的是，每次操作device前，都要求先改变mHardwareStatus的状态值，操作结束后再将其复原为AUDIO_HW_IDLE（根据源码中的注释，这样做是为了方便dump时正确输出内部状态，我们就不去深究了）。

Step4@ loadHwModule_l。把加载后的设备添加入mAudioHwDevs键值对中，其中key的值是由nextUniqueId生成的，这样做保证了这个audio interface拥有全局唯一的id号。

完成了audio interface的模块加载只是万里长征的第一步。因为每一个interface包含的设备通常不止一个，Android系统目前支持的音频设备如表13-4所示。

表13-4　Android系统支持的音频设备（输出）

Device Name	Descripti
AUDIO_DEVICE_OUT_EARPIECE	听筒
AUDIO_DEVICE_OUT_SPEAKER	喇叭
AUDIO_DEVICE_OUT_WIRED_HEADSET	带话筒的耳机
AUDIO_DEVICE_OUT_WIRED_HEADPHONE	耳机
AUDIO_DEVICE_OUT_BLUETOOTH_SCO	SCO蓝牙
AUDIO_DEVICE_OUT_BLUETOOTH_SCO_HEADSET	SCO蓝牙机
AUDIO_DEVICE_OUT_BLUETOOTH_SCO_CARKIT	SCO车载件
AUDIO_DEVICE_OUT_BLUETOOTH_A2DP	A2DP蓝牙
AUDIO_DEVICE_OUT_BLUETOOTH_A2DP_HEADPHONES	A2DP蓝牙耳机
AUDIO_DEVICE_OUT_BLUETOOTH_A2DP_SPEAKER	A2DP蓝牙喇叭

AUDIO_DEVICE_OUT_AUX_DIGITAL	AUX
AUDIO_DEVICE_OUT_ANLG_DOCK_HEADSET	模拟dock headset
AUDIO_DEVICE_OUT_DGTL_DOCK_HEADSET	数字dock headset
AUDIO_DEVICE_OUT_USB_ACCESSORY	USB配件
AUDIO_DEVICE_OUT_USB_DEVICE	USB设备
AUDIO_DEVICE_OUT_REMOTE_SUBMIX	SubMix设备
AUDIO_DEVICE_OUT_DEFAULT	默认设备
AUDIO_DEVICE_OUT_ALL	上述每种设备只占int值一个bit位，这里是指上述设备的集合
AUDIO_DEVICE_OUT_ALL_A2DP	上述设备中与A2D[illegible]蓝牙相关的设备集

	合
AUDIO_DEVICE_OUT_ALL_SCO	上述设备中与SCO蓝牙相关的设备集合
AUDIO_DEVICE_OUT_ALL_USB	上述设备中与USB相关的设备集合

读者可能会有疑问：

- 这么多的输出设备，那么当我们回放音频流（录音也是类似的情况）时，该选择哪一种呢？
- 而且当前系统中audio interface也很可能不止一个，应该如何选择？

显然这些决策工作将由AudioPolicyService来完成，我们会在下一小节做详细阐述。在此之前大家可以先来了解下，AudioFlinger是如何打开一个Output通道的（一个audio interface可能包含若干个output）。

打开音频输出通道（output）在AF中对应的接口是openOutput()，即：

```
audio_io_handle_t AudioFlinger::openOutput(audio_module_handle_t
                           *pDevices,uint32_t *pSamplingRate, aud
                                     audio_channel_mask_t *pChann
                                     uint32_t *pLatencyMs, audio_
{
    /*入参中的module是由前面的loadHwModule获得的，它是一个audio interfa
      通过此id在mAudioHwDevs中查找到对应的AudioHwDevice对象*/
    status_t status;
    PlaybackThread *thread = NULL;
    …
    audio_stream_out_t *outStream = NULL;
```

```
    audio_hw_device_t *outHwDev;
    …
    /*Step 1. 查找相应的audio interface
    outHwDev = findSuitableHwDev_l(module, *pDevices);
    …
    /*Step 2.为设备打开一个输出流*/
    audio_hw_device_t *hwDevHal = outHwDev->hwDevice();
    audio_io_handle_t id = nextUniqueId();
    mHardwareStatus = AUDIO_HW_OUTPUT_OPEN;
    status = outHwDev->open_output_stream(hwDevHal, id, *pDevices
                              (audio_output_flags_t)flags, &c
    mHardwareStatus = AUDIO_HW_IDLE;
    …
    if (status == NO_ERROR && outStream != NULL) {
      /*Step 3.生成AudioStreamOut*/
      AudioStreamOut *output = new AudioStreamOut(outHwDev, outSt
      /*Step 4.创建PlaybackThread*/
      if ((flags & AUDIO_OUTPUT_FLAG_DIRECT)||(config.format != A
                         ||(config.channel_mask != AUDIO_CHANNEL_O
            thread = new DirectOutputThread(this, output, id, *pD
    } else {
       thread = new MixerThread(this, output, id, *pDevices);
    }
    mPlaybackThreads.add(id, thread); //添加播放线程
    …
    /*Step 5.Primary output情况下的处理*/
        if ((mPrimaryHardwareDev == NULL) &&flags & AUDIO_OUTPUT_
            ALOGI("Using module %d has the primary audio interfac
            mPrimaryHardwareDev = outHwDev;
            AutoMutex lock(mHardwareLock);
            mHardwareStatus = AUDIO_HW_SET_MODE;
            hwDevHal->set_mode(hwDevHal, mMode);
            mHardwareStatus = AUDIO_HW_IDLE;
        }
        return id;
    }
    return 0;
}
```

上面这段代码中，颜色加深的部分是我们接下来分析的重点，主要还是围绕outHwDev这个变量所做的一系列操作。即：

- 查找合适的音频接口设备（findSuitableHwDev_l）；
- 创建音频输出流（通过open_output_stream获得一个audio_stream_out_t）；

- 利用AudioStreamOut来封装audio_stream_out_t与audio_hw_device_t;
- 创建播放线程（PlaybackThread）；
- 如果当前设备是主设备，则还需要进行相应的设置（比如模式设置）。

显然，outHwDev用于记录一个打开的音频接口设备，它的数据类型是audio_hw_device_t，是由HAL规定的一个音频接口设备所应具有的属性集合，如下所示：

```
struct audio_hw_device {
      struct hw_device_t common;
      …
      int (*set_master_volume)(struct audio_hw_device *dev, float
      int (*set_mode)(struct audio_hw_device *dev, audio_mode_t m
      int (*open_output_stream)(struct audio_hw_device *dev,
                                     audio_io_handle_t handle,
                                     audio_devices_t devices,
                                     audio_output_flags_t flags,
                                     struct audio_config *config,
                                     struct audio_stream_out **st
…}
```

其中common代表了所有硬件设备在HAL层都要实现的共有属性；set_master_volume、set_mode、open_output_stream分别为我们设置audio interface的主音量、设置音频模式类型（比如AUDIO_MODE_RINGTONE，AUDIO_MODE_IN_CALL等）、打开输出数据流提供了接口。

接下来我们分步阐述。

Step1@AudioFlinger::openOutput。在openOutput中，设备outHwDev是通过查找当前系统的记录得到的。代码如下：

```
AudioFlinger::AudioHwDevice* AudioFlinger::findSuitableHwDev_l(au
                                                          audio_devi
{
    if (module == 0) {//特殊的module值，此时需要加载所有interface
          ALOGW("findSuitableHwDev_l() loading well know audio hw
          for (size_t i = 0; i < ARRAY_SIZE(audio_interfaces); i+
                loadHwModule_l(audio_interfaces[i]);
        }
        for (size_t i = 0; i < mAudioHwDevs.size(); i++) {//然后再
```

```
                AudioHwDevice *audioHwDevice = mAudioHwDevs.value
                audio_hw_device_t *dev = audioHwDevice->hwDevice(
                if ((dev->get_supported_devices != NULL) &&
                         (dev->get_supported_devices(dev) & devic
                     return audioHwDevice;
        }
    } else {//直接从已有记录中查找device
        AudioHwDevice *audioHwDevice = mAudioHwDevs.valueFor(modu
        if (audioHwDevice != NULL) {
            return audioHwDevice;
        }
    }
    return NULL;
}
```

变量module值为0的情况，是为了兼容之前的Audio Policy而做的特别处理。当module等于0时，首先加载所有已知的音频接口设备，然后才能根据devices来确定其中符合要求的设备。入参devices的值实际上来源于表格“表13-4 Android系统支持的音频设备（输出）”所示的设备。可以看到，enum中每个设备类型都对应一个特定的比特位，因而上述代码段中可以通过“与运算”来找到匹配的设备。

当modules为非0值时，说明Audio Policy指定了具体的设备id号，这时就通过查找全局的mAudioHwDevs变量来确认是否存在符合要求的设备：

```
DefaultKeyedVector<audio_module_handle_t, AudioHwDevice*>  mAudio
```

变量mAudioHwDevs是一个Vector，以audio_module_handle_t为key，每一个handle唯一确定了已经添加的音频设备。那么，我们在什么时候添加设备呢？

一种情况就是前面看到的modules为0时，会load所有潜在设备；另一种情况就是AudioPolicy ManagerBase在构造函数中会预加载所有audio_policy.conf中所描述的output（后续小节有详细介绍）。不管是哪一种情况，最终都会调用loadHwModuleloadHwModule_l，这个函数我们开头就已分析过。

Step2@AudioFlinger::openOutput。调用open_output_stream打开一个audio_stream_out_t。如果从理论角度讲解这个函数，读者可能会觉得很抽象，所以这里我们提供一个具体硬件方案上的实现范例。原生

态代码中就包含了一些具体音频设备的实现，如samsung的tuna。其源码如下：

```
/*device/samsung/tuna/audio/Audio_hw.c*/
static int adev_open_output_stream(…struct audio_stream_out **str
{
    struct tuna_audio_device *ladev = (struct tuna_audio_device *
    struct tuna_stream_out *out;
    …
    *stream_out = NULL;
    out = (struct tuna_stream_out *)calloc(1, sizeof(struct tuna_
    …
    out->stream.common.set_parameters= out_set_parameters;…
    *stream_out = &out->stream;
    …
}
```

我们去掉了其中的大部分代码，只留下核心源码。可以看到，tuna_stream_out类型包含了audio_stream_out，后者就是最后要返回的结果。这种方式在HAL层的实现中很常见，读者应该熟悉这样的写法。而对于audio_stream_out的操作，无非就是根据入参需要为它的函数指针做初始化，如set_parameters的实现就最终指向了out_set_parameters。接下来的实现就涉及Linux驱动了，我们这里先不往下分析，后面音量调节小节还会再遇到这个函数。

Step3@AudioFlinger::openOutput。生成AudioStreamOut对象。这个变量没什么特别的，它把audio_hw_device_t和audio_stream_out_t作为一个整体来封装。

Step4@AudioFlinger::openOutput。既然通道已经打开，那么由谁来往通道里“填”东西呢？这就是PlaybackThread。而且分两种不同的情况：

- DirectOutput

  如果不需要混音。

- Mixer

  需要混音。

这两种情况分别对应DirectOutput Thread和MixerThread两种线程。我们以后者为例来分析下PlaybackThread的工作模式，也会为后面小节的内容打下基础。

图13-13描述了包括PlaybackThread在内的各回放线程的继承关系。

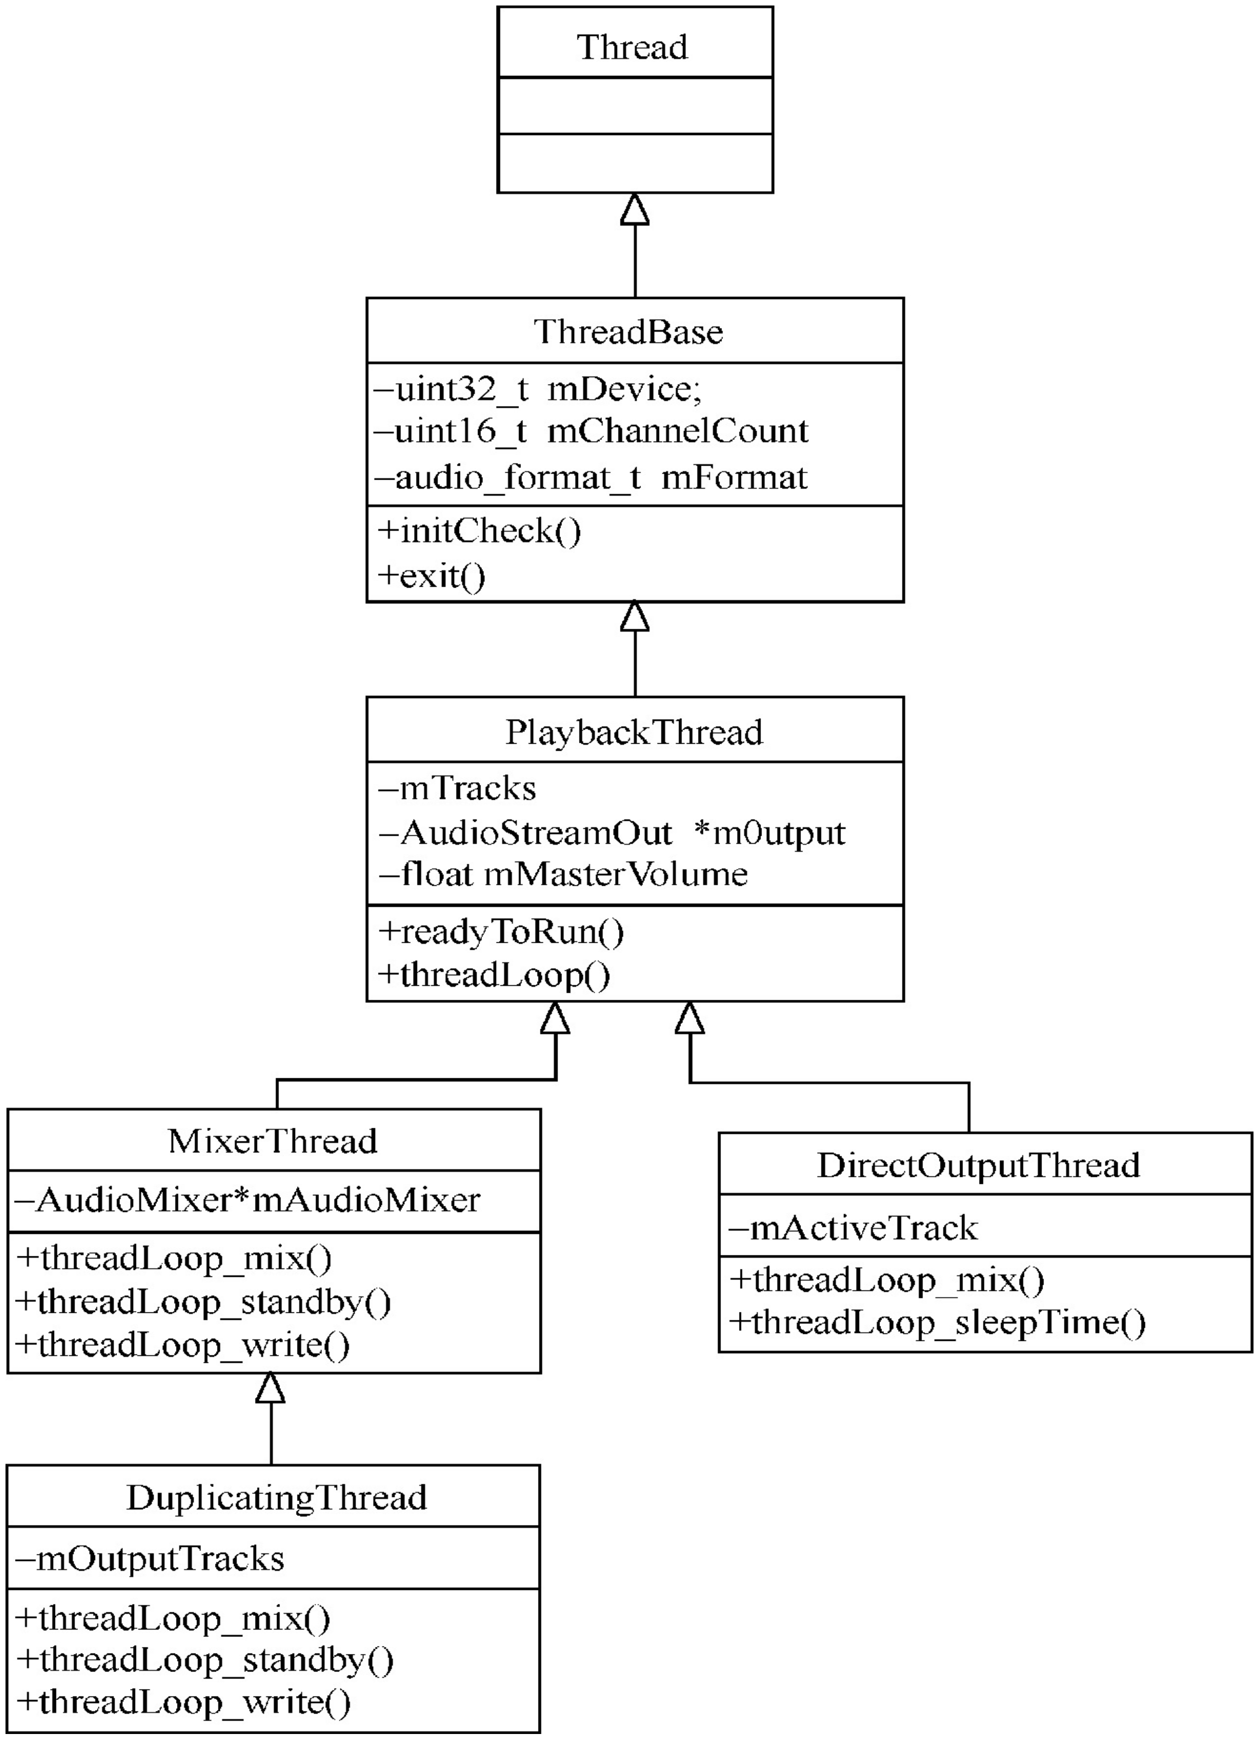
Thread
ThreadBase
–uint32_t mDevice;
–uint16_t mChannelCount
–audio_format_t mFormat
+initCheck()
+exit()
PlaybackThread
–mTracks
–AudioStreamOut *m0utput
–float mMasterVolume
+readyToRun()
+threadLoop()
MixerThread
–AudioMixer*mAudioMixer
+threadLoop_mix()
+threadLoop_standby()
+threadLoop_write()
DirectOutputThread
–mActiveTrack
+threadLoop_mix()
+threadLoop_sleepTime()
DuplicatingThread
–mOutputTracks
+threadLoop_mix()
+threadLoop_standby()
+threadLoop_write()

▲图13-13 Playback各线程类关系图

如图所示，用于Playback的线程种类不少，它们的“基类”都是Thread。

AudioFlinger中用于记录Record和Playback线程的有两个全局变量。如下：

```
DefaultKeyedVector< audio_io_handle_t, sp<PlaybackThread>>  mPlay
DefaultKeyedVector< audio_io_handle_t, sp<RecordThread>>    mReco
```

在openOutput中，加入mPlaybackThreads的是一个新建的线程类实例，如MixerThread。它的构造函数如下：

```
AudioFlinger::MixerThread::MixerThread(…):PlaybackThread(audioFli
device, type),…
{   …
    mAudioMixer = new AudioMixer(mNormalFrameCount, mSampleRate);
    if (mChannelCount != FCC_2) {//非双声道的情况下
        ALOGE("Invalid audio hardware channel count %d", mChannel
    }
    mOutputSink = new AudioStreamOutSink(output->stream);
    …
    if (initFastMixer) {
        …
    } else {
        mFastMixer = NULL;
    }
    …
}
```

首先生成一个AudioMixer对象，这是混音处理的关键，我们在后面会有详细介绍。然后检查声道数量，在Mixer情况下肯定不止一个声道。接着创建一个NBAIO（Non-blocking audio I/O interface）Sink（即AudioStreamOutSink），并进行negotiate。最后根据配置（initFastMixer）来判断是否使用fast mixer。

可以想象一下，一个放音线程的任务就是“不断”处理上层的音频数据回放请求，然后将其传递到下一层，最终写入硬件设备。但是在上面这个函数中，似乎并没有看到程序去启动一个新线程，也没有看到进入线程循环的地方，或者去调用其他可能引起线程创建的函数。那么，

究竟在什么情况下MixerThread才会真正进入线程循环呢？

不知读者有没有注意到之前mPlaybackThreads的定义，我们再次列出如下：

```
DefaultKeyedVector< audio_io_handle_t, sp<PlaybackThread>>  mPlay
```

它实际上是由audio_io_handle_t和PlaybackThread强指针所组成的键值对；同时也可以判断出，PlaybackThread类的祖先中一定会有RefBase。具体来说，就是它的“父类”Thread继承自RefBase：

```
/*frameworks/native/include/utils/Thread.h*/
class Thread : virtual public RefBase
{…
```

根据强指针的特性，目标对象在第一次被引用时是会调用onFirstRef的，这点在前面小节分析AudioFlinger时也见过。函数实现如下：

```
void AudioFlinger::PlaybackThread::onFirstRef()
{
     run(mName, ANDROID_PRIORITY_URGENT_AUDIO);
}
```

很简单，只是调用了run方法，从而启动一个新线程并间接调用threadLoop，不断地处理Mix业务。这样我们就明白一个PlaybackThread是如何进入线程循环的，至于循环中需要做些什么，留在下一小节做详细介绍。

Step5@ AudioFlinger::openOutput。到目前为止，我们已经成功地建立起一个音频通道，就等着AudioTrack往里“丢”数据了。不过假如当前的output是“primary”的，则还有一些额外的工作要做，如模式的设置。

我们来整理下这个小节所阐述的内容。

- 当AudioPolicyManagerBase构造时，它会根据用户提供的audio_policy.conf来分析系统中有哪些Audio Interface（primary，a2dp以及usb），然后通过AudioFlinger::loadHwModule加载各Audio Interface对应的库文件，并依次打开其中的Output(openOutput)和

Input(openInput)。

- 我们详细分析了openOutput所做的工作，包括打开一个audio_stream_out_t通道，生成AudioStreamOut对象，以及新建PlaybackThread等。此时“万事俱备，只欠东风”，只要AudioTrack不断和AudioFlinger传递数据，整个音频回放就开始了。当然，这其中还涉及状态的管理、路由切换以及数据的跨进程通信等事宜，这些都是我们后面内容所要解决的。

13.3.3 PlaybackThread的循环主体

当一个PlaybackThread进入主循环后（threadLoop），音频事务就正式开启了。仔细观察，就会发现这个循环中会不断地调用以“threadLoop_”开头的若干接口，如threadLoop_mix、threadLoop_sleepTime、threadLoop_standby等。以“threadLoop”的前缀开头，是因为这些函数都是在threadLoop这个主体里被调用的，可以说代表了这个PlaybackThread所需要完成的各个操作步骤。

从前一小节可以了解到，当程序执行到PlaybackThread::onFirstRef时会去启动一个线程来承载threadLoop的运行。接下来我们具体看看这个循环体中的处理流程：

```
bool AudioFlinger::PlaybackThread::threadLoop()
{…
    while (!exitPending())/*Step 1.注意循环条件*/
    {…
        processConfigEvents();/*Step 2. */
        { /*把这段代码框起来的目的是限制自动锁变量_l的生命期，从而灵活地实现
            Mutex::Autolock _l(mLock);
          …
            /*Step 3. Standby判断*/
            if (CC_UNLIKELY((!mActiveTracks.size() && systemTime(
                                                                 ||is
                if (!mStandby) {
                    threadLoop_standby();//进入standby
                    mStandby = true;
                }
              …
            }
          /*Step 4.准备音频数据*/
             mMixerStatus = prepareTracks_l(&tracksToRemove);
             …
```

```
        }
       /*Step 5.准备就绪，开始mix*/
        if (CC_LIKELY(mMixerStatus == MIXER_TRACKS_READY)) {
            threadLoop_mix();
        } else {
            threadLoop_sleepTime();//否则休眠一段时间
        }
        …
        /*Step 6.*/
        if (sleepTime == 0) {//sleepTime为0，代表我们必须写入音频硬件设
            threadLoop_write();
           …
            mStandby = false;
        } else {
            usleep(sleepTime); //进入休眠，时间长短是sleepTime
        }
        /*Step 7.*/
        threadLoop_removeTracks(tracksToRemove); //移除相关Track
        tracksToRemove.clear();…
    }//while (!exitPending())结束
    …
    releaseWakeLock();
    return false;
}
```

Step1@ PlaybackThread::threadLoop。循环的条件是!exitPending()为true。这个函数属于Thread类，它主要通过判断内部变量mExitPending的值来得出是否要结束线程。变量mExitPending在Thread初始化时为fasle，如果后面有人通过requestExit()，requestExitAndWait等函数来请求主动退出，这个值就会改变，从而使得PlaybackThread结束循环。

Step2@PlaybackThread::threadLoop。处理config事件。当有配置变更的事件发生时，可以通过sendConfigEvent来通知PlaybackThread。这个函数将把事件添加到mConfigEvents全局变量中，以供processConfigEvents进行处理。配置事件包括如下几种：

```
    enum io_config_event {
        OUTPUT_OPENED, //Output打开
        OUTPUT_CLOSED, //Output关闭
        OUTPUT_CONFIG_CHANGED, //Output配置改变
        INPUT_OPENED, //Input打开
        INPUT_CLOSED, //Input关闭
        INPUT_CONFIG_CHANGED,//Input配置改变
```

```
        STREAM_CONFIG_CHANGED,//Stream配置改变
        NUM_CONFIG_EVENTS
    };
```

Step3@ PlaybackThread::threadLoop。判断当前是否符合Standby的条件，如果是就调用threadLoop_standby。这个函数最终还是通过HAL层的接口来实现，如下所示：

```
mOutput->stream->common.standby(&mOutput->stream->common);
```

Step4@ PlaybackThread::threadLoop。进行数据准备，prepareTracks_l这个函数非常长，我们先用伪代码的形式整理一下它所做的工作，如下所示：

```
AudioFlinger::PlaybackThread::mixer_state AudioFlinger::MixerThre
{
    /*Step 1. 当前活跃的Track数量*/
    size_t count = mActiveTracks.size();

    /*Step 2. 循环处理每个Track，这是函数的核心*/
    for (size_t i=0 ; i<count ; i++) {
        Track* track = mActiveTracks[i];//伪代码没有考虑强指针

        /*Step 3. FastTrack下的处理*/
        if(track is FastTrack?)
        {
               //do something;
        }
        /*Step 4. 准备数据，细分为以下几个小步骤来完成*/
       audio_track_cblk_t* cblk = track->cblk(); //Step 4.1 数据块

        /*Step 4.2 回放音频，至少需要准备多少帧数据？*/
        uint32_t minFrames = 1;//初始化
        //具体计算minFrames的过程…

        /*Step 4.3 如果数据已经准备完毕，那么：
          //调整音量
          //其他参数设置*/
    }//for循环结束

     /*Step 5. 后续判断*/
     //返回结果，指明当前状态是否已经ready
}
```

现在，我们针对上面的步骤来做“填空”。

Step1@MixerThread::prepareTracks_l。mActiveTracks的数据类型是SortedVector，用于记录当前活跃的Track。它会随着新的AudioTrack的加入而扩大，也会在必要的情况下（AudioTrack工作结束或者出错等）remove相应的Track。

Step2&Step3@MixerThread::prepareTracks_l。循环的条件就是要逐个处理该PlaybackThread中包含的所有Tracks。假如当前是一个FastTrack，我们还要做一些额外的准备工作，暂时不去涉及具体细节。

Step4@ MixerThread::prepareTracks_l。这一步是准备工作中最重要的，即缓冲数据。在学习代码细节前，我们先来了解数据传输时最容易出现的underrun问题。

什么是Buffer Underrun呢？

当两个设备或进程间形成“生产者-消费者”关系时，如果生产的速度不及消费者消耗的速度，就会出现Underrun。以音频回放为例，此时用户听到的声音就可能是断断续续的，或者是重复播放当前buffer中的数据（取决于具体的实现）。

如何避免这种异常的发生呢？这是AudioTrack和AudioFlinger需要协同解决的问题。我们可以先看看“消费者”端的处理。

Step4分为以下几个子步骤。

- Step 4.1准备音频数据块:

```
audio_track_cblk_t* cblk = track->cblk();
```

关于audio_track_cblk_t的更多描述，可以参见后面的数据流小节。

- Step 4.2计算此次回放音频所需的最少帧数，初始值为1:

```
    uint32_t minFrames = 1;
    if ((track->sharedBuffer() == 0) && !track->isStopped() &
            (mMixerStatusIgnoringFastTracks == MIXER_TRACKS_R
        if (t->sampleRate() == (int)mSampleRate) {
             minFrames = mNormalFrameCount;
```

```
        } else {
            minFrames = (mNormalFrameCount * t->sampleRate()) / m
            minFrames += mAudioMixer->getUnreleasedFrames(track->
            ALOG_ASSERT(minFrames <= cblk->frameCount);
        }
}
```

当track->sharedBuffer()为0时，说明这个AudioTrack不是STATIC模式的，即数据不是一次性传送的（可以参见AudioTrack小节的描述）。全局变量mSampleRate是通过mOutput->stream->common.get_sample_rate获得的，它由HAL提供，代表的是设备的Sampling Rate。

如果两者一致，就采用mNormalFrameCount，这个值在readOutputParameters函数中进行初始化；如果两者不一致，就要预留多余空间做rounding(+1)和interpolation(+1)。另外，还需要考虑未释放的空间大小，也就是getUnreleasedFrames得到的。得出的minFrames必须小于数据块的总大小，因而最后有个ASSERT。通常情况下frameCount分配的是一个buffer的两倍，可以参见AudioTrack小节的例子。

- Step 4.3数据是否准备就绪。

上一步我们计算出了数据的最小帧值，即minFrames。接下来就应该判断当前的实际情况是否符合这一指标了。代码如下：

```
    if ((track->framesReady() >= minFrames) && track->isReady() &
            && !track->isTerminated())
        {//数据准备就绪，并处于ready状态
            mixedTracks++;//需要mix的Track数量增加1
            …
            /*计算音量值*/
            uint32_t vl, vr, va; //3个变量分别表示左、右声道和Aux Leve
            if (track->isPausing() ||mStreamTypes[track->streamTy
                   vl = vr = va = 0; //当静音时，变量直接赋0
                   if (track->isPausing()) {
                         track->setPaused();
                   }
            } else {
                   /*这里获得的是针对每个stream类型设置的音量值，也就是后
                      后执行到的地方，在这里就起到作用了*/
            float typeVolume = mStreamTypes[track->streamType()].
                float v = masterVolume * typeVolume; //主音量和类型
```

```
            ServerProxy *proxy = track->mServerProxy;
                uint32_t vlr = proxy->getVolumeLR();//这里得到的vlr
                vl = vlr & 0xFFFF; //vlr的高低位分别表示vr和vl
                vr = vlr >> 16;
                if (vl > MAX_GAIN_INT) { //对vl进行合理值判断
                    ALOGV("Track left volume out of range: %04X",
                    vl = MAX_GAIN_INT;
                }
                if (vr > MAX_GAIN_INT) {//对vr进行合理值判断
                    ALOGV("Track right volume out of range: %04X"
                    vr = MAX_GAIN_INT;
                }
                // now apply the master volume and stream type vo
                vl = (uint32_t)(v * vl) << 12;
                vr = (uint32_t)(v * vr) << 12;
                uint16_t sendLevel = proxy->getSendLevel_U4_12();
                …
                va = (uint32_t)(v * sendLevel);
            }…
            mAudioMixer->setParameter(name, param, AudioMixer::VO
            mAudioMixer->setParameter(name, param, AudioMixer::VO
            mAudioMixer->setParameter(name, param, AudioMixer::AU
            …
        } else {//数据未准备就绪的情况下，源代码略…
```

对于音量的设置还有很多细节，读者有兴趣的可以自行研究下。在得到vl，vr和va的值后，需要把它们应用到AudioMixer里。不过在prepareTracks_l中还只是调用mAudioMixer->se tParameter设置了这些参数，真正的实现是在threadLoop_mix中，我们后面会讲到这个函数。

Step5@ MixerThread::prepareTracks_l。通过对每个Track执行上述处理后，最后要返回一个结果。这通常取决于：

（1）是否有active track；

（2）active track的数据是否已经准备就绪。

返回的最终值将影响到threadLoop的下一步操作。

完成了prepareTracks_l的分析，我们再回到前面的threadLoop。

Step5@ PlaybackThread::threadLoop。如果上一步的数据准备工

作已经完成（即返回值是MIXER_TRACKS_READY），就开始进行真正的混音操作，即threadLoop_mix，否则会休眠一定的时间——如此循环往复直到退出循环体：

```
void AudioFlinger::MixerThread::threadLoop_mix()
{
    int64_t pts;
    …
    mAudioMixer->process(pts);
    …
}
```

这样就进入AudioMixer的处理了，我们放在下一小节做统一分析。

假如数据还没有准备就绪，那么AudioFlinger将调用threadLoop_sleepTime来计算需要休眠多长时间（变量sleepTime），并在threadLoop主循环的末尾（在remove track之前）执行usleep进入休眠。

Step6@ PlaybackThread::threadLoop。将数据写到HAL中，从而借助后者逐步写入硬件设备中：

```
void AudioFlinger::PlaybackThread::threadLoop_write()
{
    mLastWriteTime = systemTime();//记录上次写入时间
    mInWrite = true;
    int bytesWritten;
    if (mNormalSink != 0) {//NBAIO的情况下
        …
        ssize_t framesWritten = mNormalSink->write(mMixBuffer, co
        …
    } else {
        bytesWritten = (int)mOutput->stream->write(mOutput->strea
    }
    if (bytesWritten > 0) mBytesWritten += mixBufferSize;
    mNumWrites++;
    mInWrite = false;
}
```

分为两种情况：

- 如果是采用了NBAIO(Non-blocking Audio I/O)，即在mNormalSink不为空的情况下，则通过它写入HAL设备。

- 否则使用普通的AudioStreamOut（即mOutput变量）将数据输出。

Step7@ PlaybackThread::threadLoop。移除tracksToRemove中指示的Tracks。是否移除一个Track是在prepareTracks_l中判断，可以概括为以下几种情况。

- 对于Fast Track，如果它的状态（mState）是STOPPING_2，PAUSED，TERMINATED，STOPPED，FLUSHED，或者状态是ACTIVE但underrun的次数超过限额（mRetryCount），则会被加入tracksToRemove列表中。

- 在当前的Track数据未准备就绪的情况下，且是STATIC TRACK或者已经停止/暂停，也会被加入tracksToRemove列表中。

在tracksToRemove列表中的Track，与其相关的output将收到stop请求（由AudioSystem:: stopOutput发起）。

关于AudioFlinger中与AudioTrack，AudioPolicyService交互的部分，我们接下来将继续阐述。

13.3.4 AudioMixer

每一个MixerThread都有一个唯一对应的AudioMixer（在MixerThread中用mAudioMixer表示）对象，它的作用就是完成音频的混音操作，其示意图如图13-14所示。

如图13-14所示，AudioMixer对外开放的接口主要涉及Parameter（如setParameter）、Resampler（如setResampler）、Volume（如adjustVolumeRamp）、Buffer（如setBufferProvider）及Track（如getTrackName）5个部分。

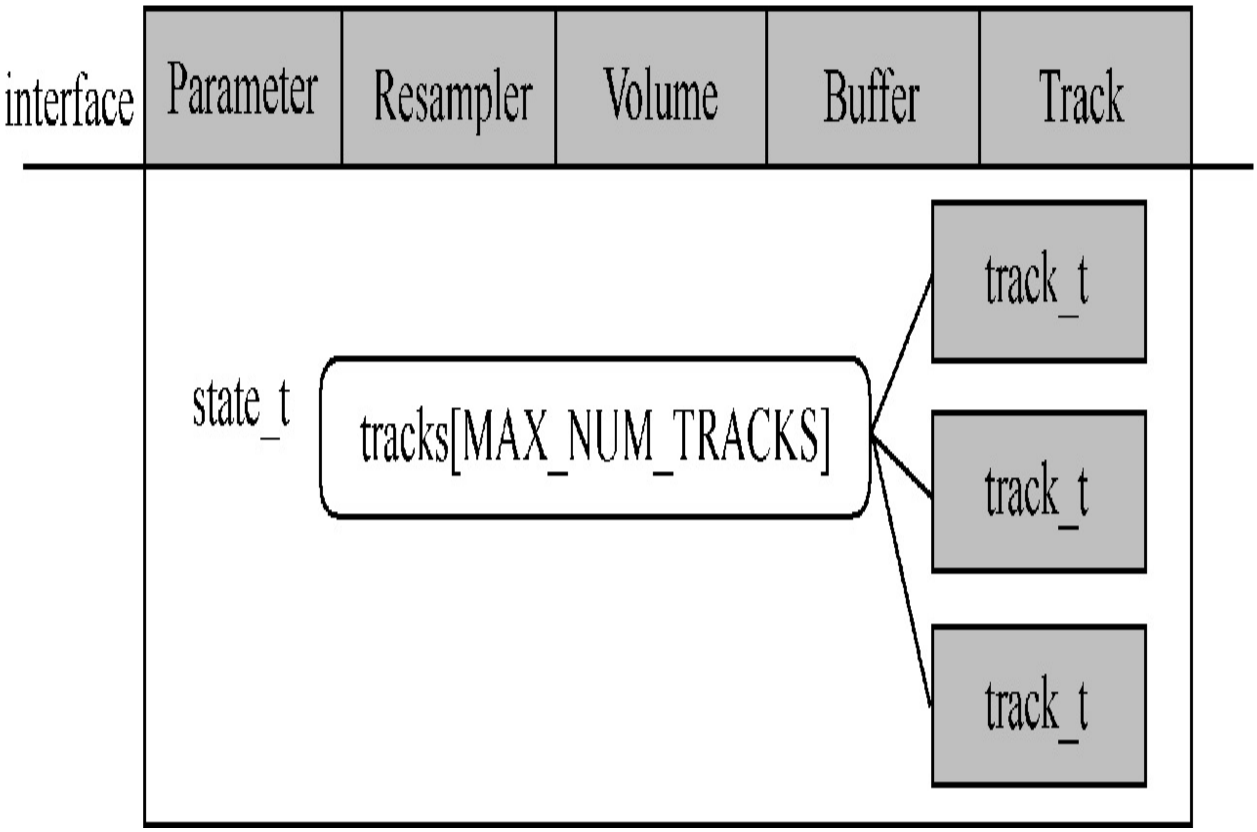

▲图13-14　AudioMixer示意

在内部的实现中，MixerThread的核心是一个mState变量（state_t类型），所有的混音工作都会在这个变量中体现出来——特别是其中的tracks数组，如下所示：

```
struct state_t {
     uint32_t  enabledTracks;
     uint32_t  needsChanged;
     size_t    frameCount;
     void      (*hook)(state_t* state, int64_t pts);   // one
     int32_t   *outputTemp;
     int32_t   *resampleTemp;
     NBLog::  Writer*    mLog;
     int32_t    reserved[1];
     track_t    tracks[MAX_NUM_TRACKS]; __attribute__((aligne
};
```

MAX_NUM_TRACKS=32，即最多支持32路同时混音，这在大部分情况下肯定足够了。数据类型track_t是对每个Track的描述——可想而知类似setParameter的设置接口，最终影响的就是Track的属性：

```
    struct track_t {
        …
        union {
        int16_t     volume[MAX_NUM_CHANNELS];
        int32_t     volumeRL;
        };//音量相关的属性
        int32_t     prevVolume[MAX_NUM_CHANNELS];
        int32_t     volumeInc[MAX_NUM_CHANNELS];
        …
        uint8_t     channelCount; //只能是1或2
        uint8_t     format;        // 总是16
        uint16_t    enabled;       // 实际是布尔类型
        audio_channel_mask_t channelMask;
        AudioBufferProvider*               bufferProvider;
        mutable AudioBufferProvider::Buffer buffer; // 8 bytes
        hook_t      hook;
        const void* in; //buffer中的当前位置
        AudioResampler*     resampler;
        uint32_t            sampleRate;
        int32_t*           mainBuffer;
        int32_t*           auxBuffer;
        …
        bool        setResampler(uint32_t sampleRate, uint32_t de
        bool        doesResample() const { return resampler != NU
        void        resetResampler() { if (resampler != NULL) res
        void        adjustVolumeRamp(bool aux);
        size_t getUnreleasedFrames() const { return resampler !=
                                   resampler->getUnreleas
    };
```

AudioFlinger的threadLoop中，通过不断调用prepareTracks_l来准备数据，而每次prepare实际上都是对所有Tracks的一次调整。如果属性有变化，就会通过setParamter来告知AudioMixer。

在前一个小节中，threadLoop_mix在内部就是通过AudioMixer来实现混音的。具体如下：

```
void AudioMixer::process(int64_t pts)
{
    mState.hook(&mState, pts);
}
```

“hook”是钩子的意思，为什么取这个名字呢？一个原因可能是hook指向的实体是变化的——所以就好像钩子一样，需要灵活地依附于各种物体之上。从代码层面来看，hook是一个函数指针，它根据不同场

景会分别指向以下几个函数实现。

process__validate：根据当前的具体情况，进一步将hook导向下面的几个函数。

process__nop：初始值。

process__OneTrack16BitsStereoNoResampling：只有一路Track，16比特立体声，不重采样。

process__genericNoResampling：两路（包含）以上Track，不重采样。

process__genericResampling：两路（包含）以上Track，重采样。

hook在以下几种情况下会被重新赋值。

- AudioMixer初始化时，hook指向process_nop。
- 状态改变或者参数变化时（比如setParameter），调用invalidateState，hook指向process__validate。
- AudioMixer::process是外部程序调用hook的入口。

我们以简图来描述一下，大家也许会看得更清楚些，如图13-15所示。

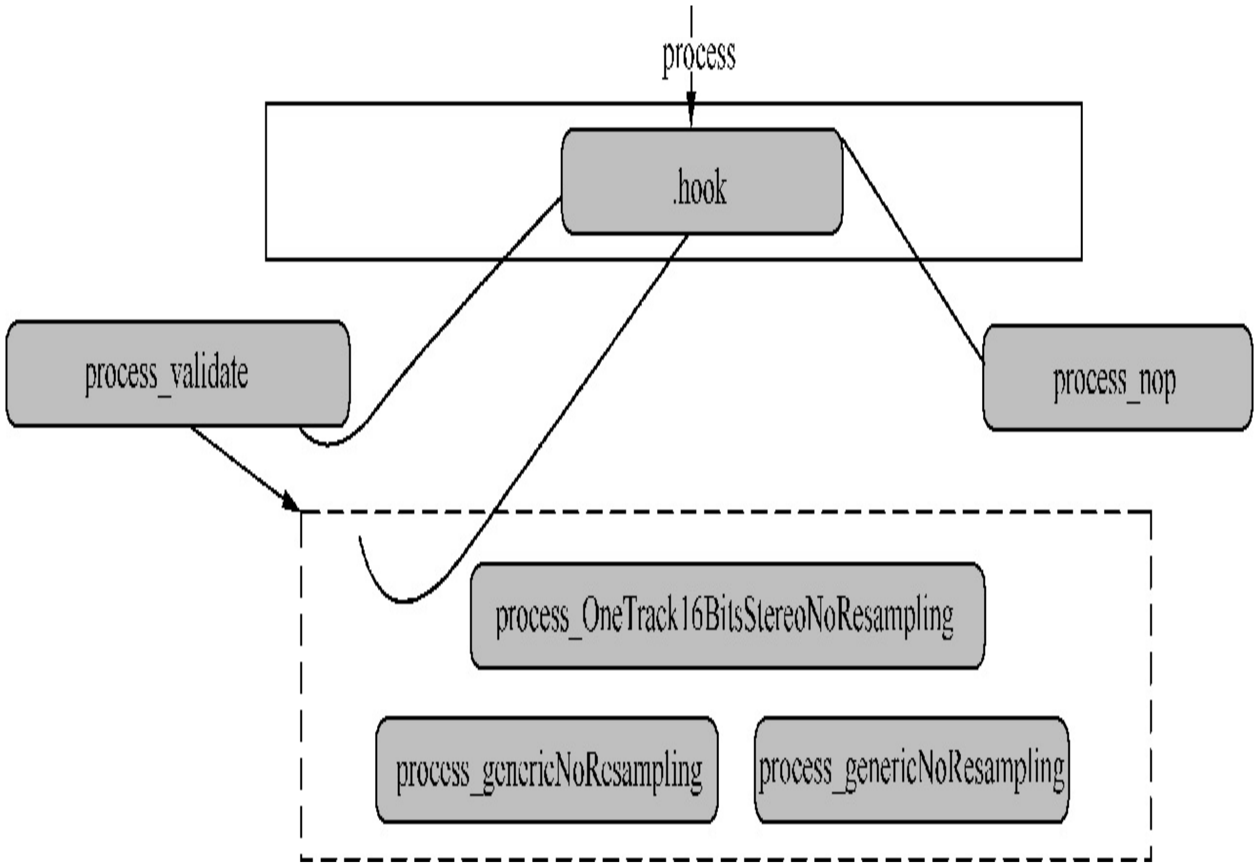

▲图13-15　hook的使用

其中，process_validate的代码实现如下：

```
void AudioMixer::process__validate(state_t* state, int64_t pts)
{…
    int countActiveTracks = 0;
    bool all16BitsStereoNoResample = true;
    bool resampling = false;…
    uint32_t en = state->enabledTracks;
    while (en) {
        const int i = 31 - __builtin_clz(en);
        en &= ～(1<<i);
        countActiveTracks++; //enabled 状态的Track计数
        …
    }
    state->hook = process__nop;
    if (countActiveTracks) {
        if (resampling) {
            …
            state->hook = process__genericResampling;
        } else {
```

```
            …
            state->hook = process__genericNoResampling;
            if (all16BitsStereoNoResample && !volumeRamp) {
                if (countActiveTracks == 1) {
                    state->hook = process__OneTrack16BitsStereoNo
                }
            }
        }
    }
   state->hook(state, pts);
   …
}
```

这个函数先通过while循环逐个分析处于enabled状态的Track，统计其内部各状态位（如NEEDS_AUXMASK、NEEDS_RESAMPLEMASK等）情况，得出countActiveTracks、resampling、volumeRamp及all16BitsStereoNoResample的合理值，最后基于这几个变量来选择正确的hook实现，并调用这个hook函数执行具体工作。

至于AudioMixer是如何处理音频数据的，我们将在音频流小节做统一分析。

13.4 策略的制定者——AudioPolicyService

在AudioFlinger小节，我们反复强调它只是策略的执行者，而AudioPolicyService才是策略的制定者。这种分离设计有效地降低了整个音频系统的耦合性，而且为各个模块独立扩展功能提供了基础保障。

13.4.1 AudioPolicyService概述

汉语中有很多与策略有关联的俗语，如“因地制宜”“具体问题具体分析”；战争中只遵照兵书来制定战术的行为也被称为“纸上谈兵”“死读书”。这些都告诉我们，了解策略的执行环境非常重要，只有清晰地界定出“问题是什么”，才能有的放矢地制定出正确的Policy以解决问题。

从功能的角度来讲，Android系统中的声音被划分为多个种类。具体如下所示：

```
/*frameworks/base/media/java/android/media/AudioSystem.java*/
    public static final int STREAM_VOICE_CALL = 0; /* 通话声音*/
    public static final int STREAM_SYSTEM = 1; /* 系统声音*/
    public static final int STREAM_RING = 2; /* 电话铃声和短信提示 *
    public static final int STREAM_MUSIC = 3; /* 音乐播放 */
    public static final int STREAM_ALARM = 4; /* 闹铃 */
    public static final int STREAM_NOTIFICATION = 5; /* 通知声音 *

    /*下面几个是隐藏类型，不对上层应用开放*/
    public static final int STREAM_BLUETOOTH_SCO = 6; /*蓝牙通话*/
    public static final int STREAM_SYSTEM_ENFORCED = 7; /* 强制的系
                                                    要求摄像头拍照时有
    public static final int STREAM_DTMF = 8; /* DTMF声音 */
    public static final int STREAM_TTS = 9; /* 即text to speech (
```

针对这么多音频类型，AudioPolicyService至少面临如下几个问题。

- 问题1：这些类型的声音需要输出到哪些对应的音频回放设备中?

比如一部典型的手机，它既有听筒、耳机接口，还有蓝牙设备。假设默认情况下播放音乐是通过听筒喇叭输出的，那么当用户插入耳机时，这个策略就会改变——从耳机输出，而不再是听筒；又如在机器插

着耳机时，播放音乐不应该从喇叭输出，但是当有来电铃声时，就需要同时从喇叭和耳机输出音频。这些“音频策略”的制定，其主导者就是AudioPolicyService。

- 问题2：声音的路由策略如何？

如果把一个音乐播放实例（比如用MediaPlayer播放一首SD卡中的歌曲）比作源IP，那么上一问题中找到的音频播放设备就是目标IP。在TCP/IP体系中，从源IP最终到达目标IP通常需要经过若干个路由器节点——由路由器根据一定的算法来决定下一个匹配的节点是什么，从而制定出一条最佳的路由路径，如图13-16所示。

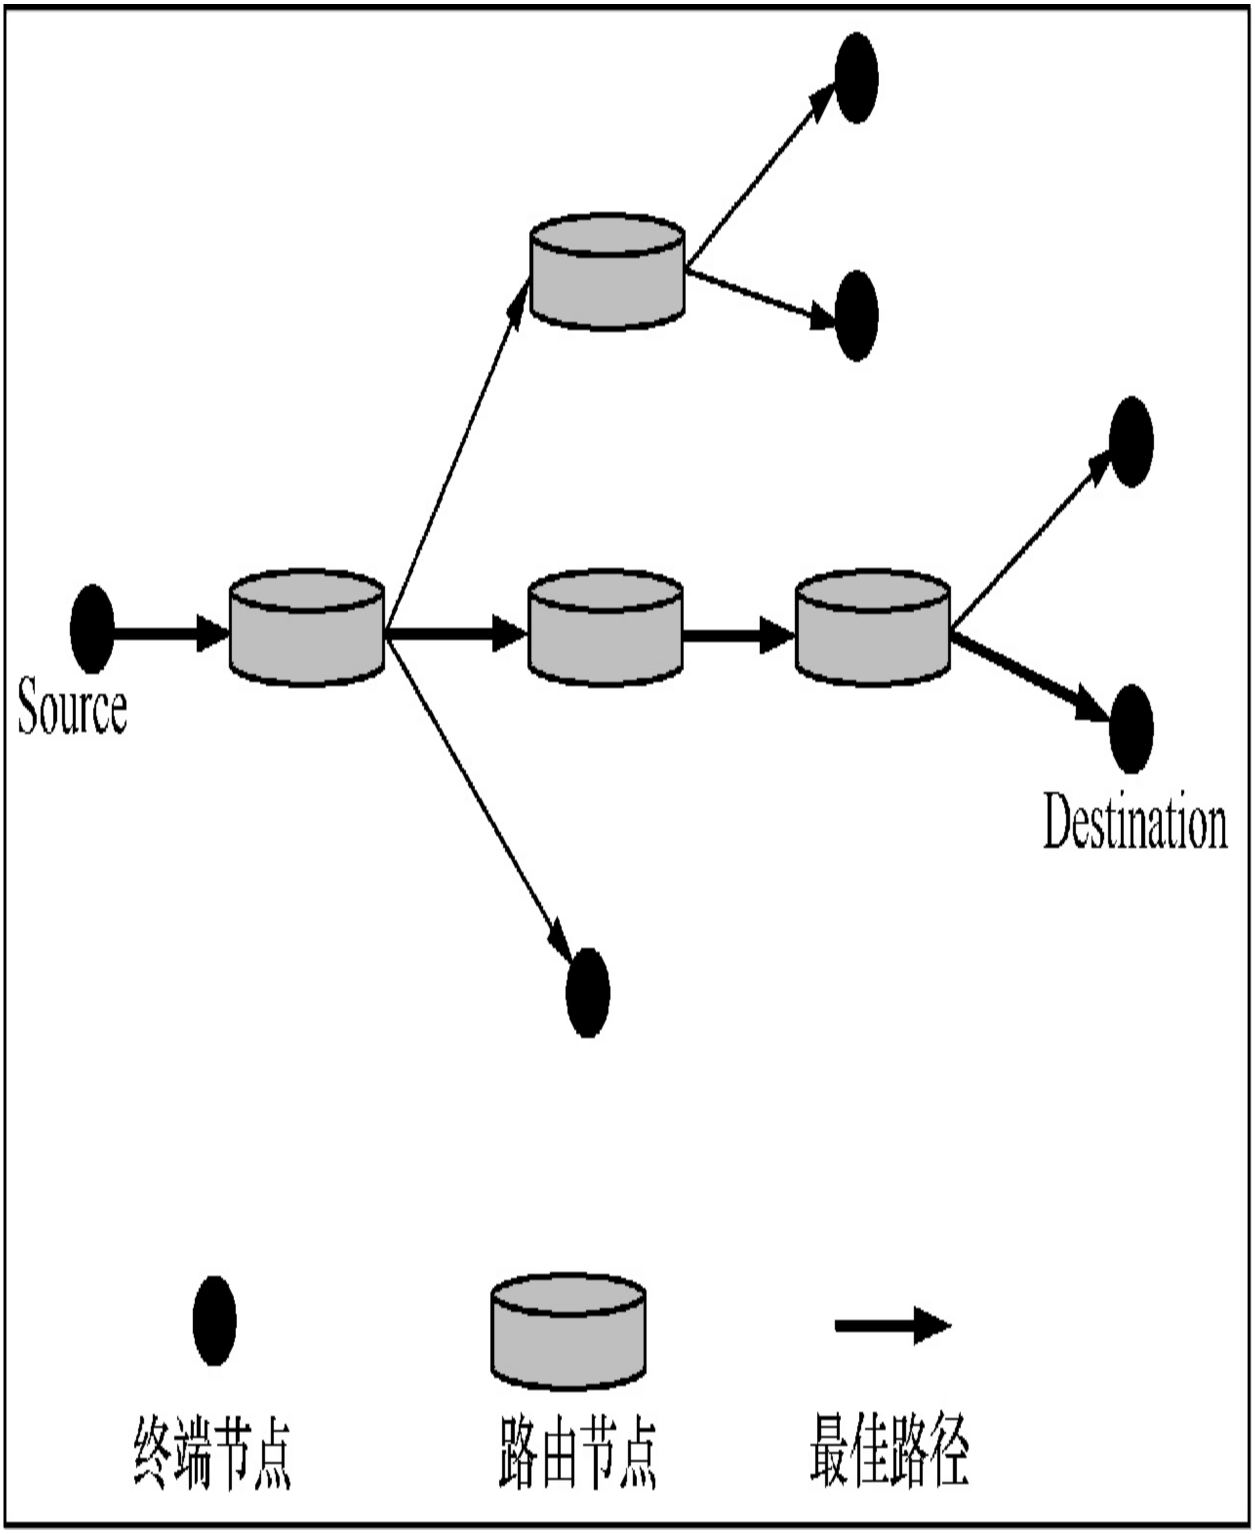

▲图13-16　路由器示意图

AudioPolicyService所要解决的问题与路由器类似。因为系统中很

可能存在多个Audio Interface，每一个Audio Interface包含若干个output，而每个output又同时支持若干种音频设备——这就意味着从播放实例到终端设备需要经过Audio Interface和output的选择，被称为AudioPolicyService的路由功能。

- 问题3：每种音频类型的音量调节是否一样？

不同类型的音频，其音量的可调节范围是不一样的。比如有的是0～15，而有的则是1～20；而且它们的默认值也是有差别的，我们看看AudioManager中的定义：

```
public static final int[] DEFAULT_STREAM_VOLUME = new int[] {
    4,  // STREAM_VOICE_CALL
    7,  // STREAM_SYSTEM
    5,  // STREAM_RING
    11, // STREAM_MUSIC
    6,  // STREAM_ALARM
    5,  // STREAM_NOTIFICATION
    7,  // STREAM_BLUETOOTH_SCO
    7,  // STREAM_SYSTEM_ENFORCED
    11, // STREAM_DTMF
    11  // STREAM_TTS
};
```

关于音量的调节后面我们用专门的小节来介绍。

为了让读者对AudioPolicyService有个感性的认识，我们以图13-17来形象地表示它与AudioTrack及AudioFlinger的关系。

图13-17中的元素包括了AudioPolicyService、AudioTrack、AudioFlinger、PlaybackThread以及两个音频设备（喇叭、耳机）。它们之间的关系如下（特别注意，本例的目的只是说明这些元素间的关系，有些细节方面后续还会做进一步完善）。

- 一个PlaybackThread的输出对应了一种设备。

比如图中有两个设备，就有两个PlaybackThread与之对应。左边的Thread最终混音后输出到喇叭，而右边的则输出到耳机。

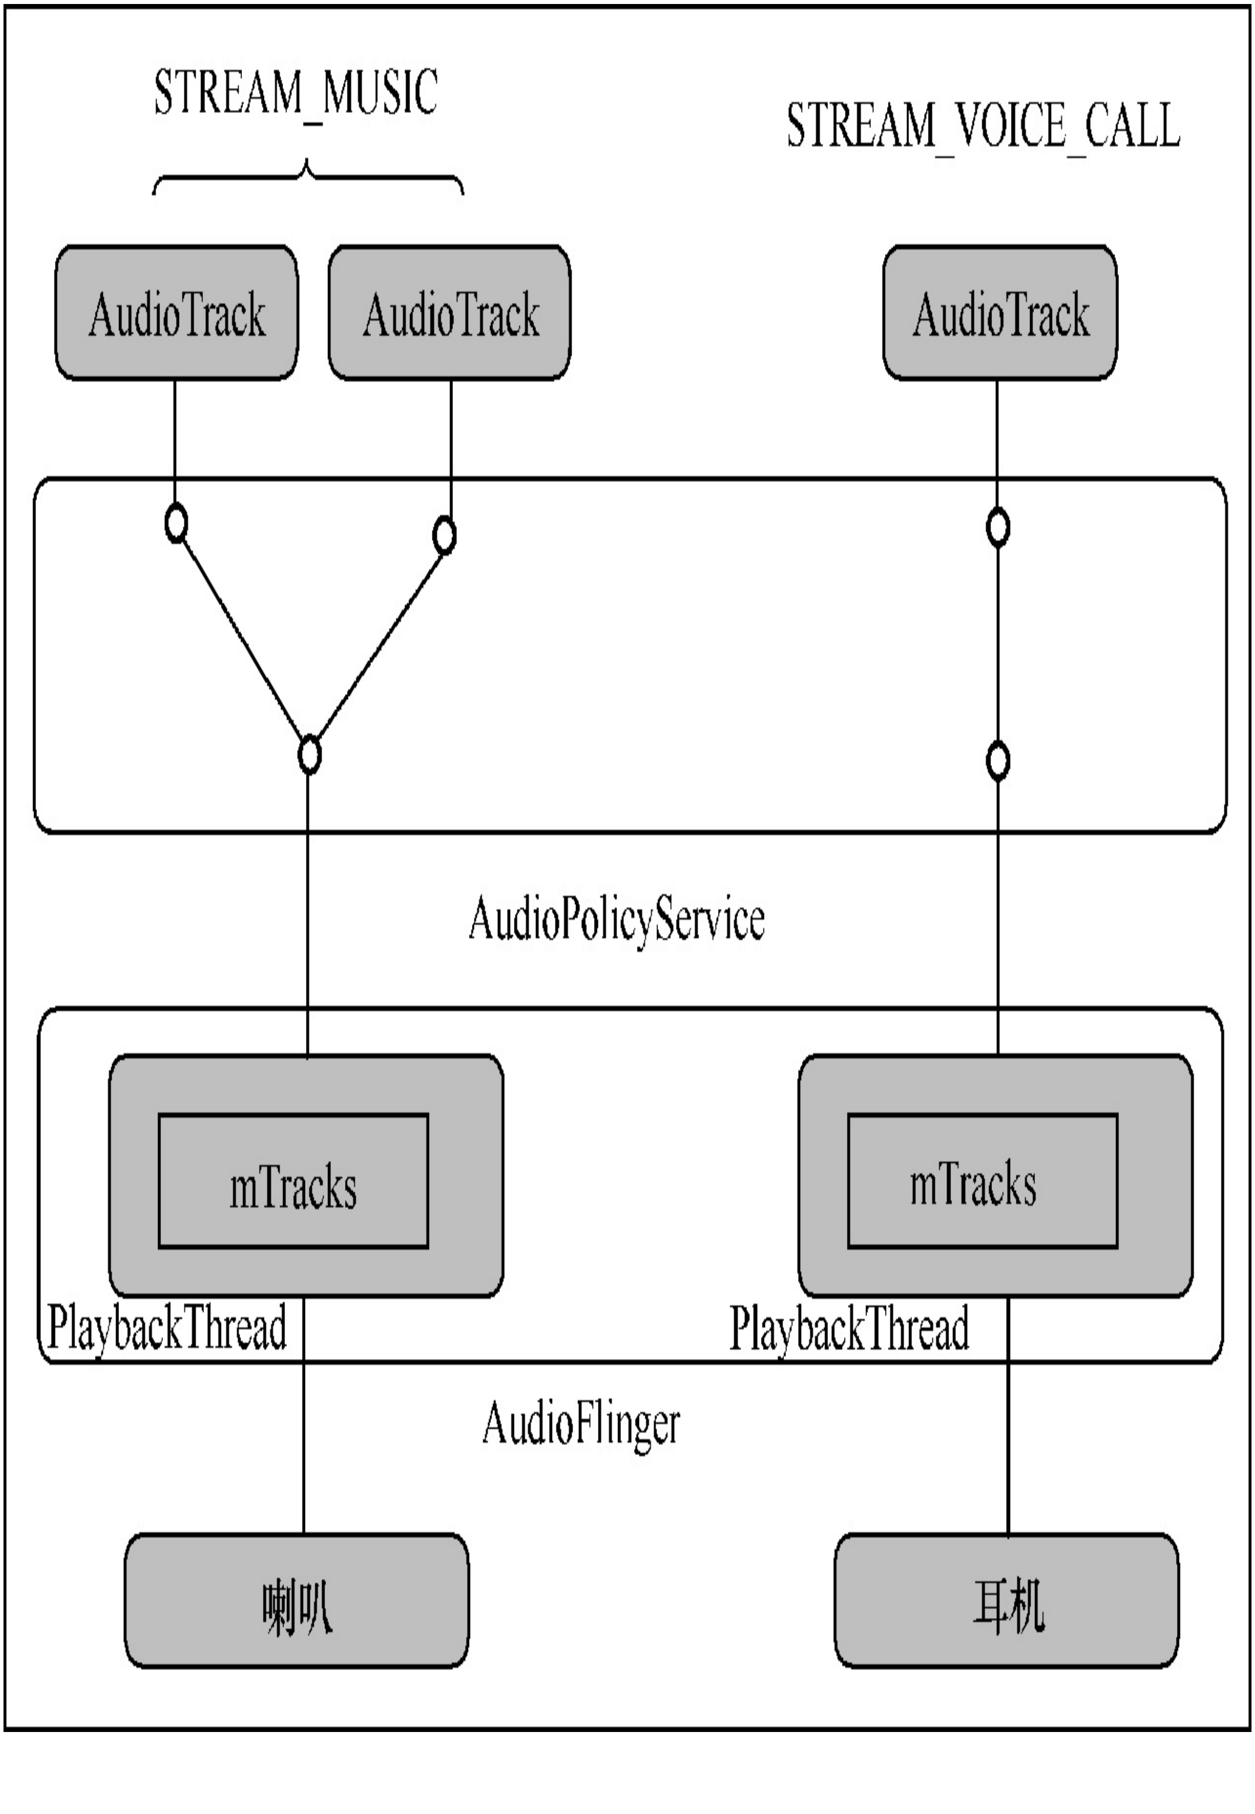
STREAM_MUSIC
STREAM_VOICE_CALL
AudioTrack
AudioTrack
AudioTrack
AudioPolicyService
mTracks
mTracks
PlaybackThread
PlaybackThread
AudioFlinger
喇叭
耳机

▲图13-17　AudioPolicyService与AudioTrack、AudioFlinger的关系图

- 在特定的时间，同一类型的音频对应的输出设备是统一的。

也就是说，如果当前STREAM_MUSIC对应的是喇叭，那么所有该类型的音频都会输出到喇叭。结合上一点我们还可以得出一个结论，即同一类型音频对应的PlaybackThread也是一样的。

- AudioPolicyService起到了路由器的作用。

AudioPolicyService在整个选择过程中的作用有点类似于网络路由器，它有权决定某一个AudioTrack所产生的“音频数据”最终会“流”向哪个设备，就像路由器可以根据一定的算法来决定发送者的数据包下一步应该传递给哪个节点一样。

接下来我们从以下几方面来考查AudioPolicyService：

（1）从启动过程来看AudioPolicyService的工作方式；

（2）AudioPolicyService如何通过AudioFlinger去管理音频设备；

（3）结合上面的关系图详细分析AudioPolicyService是如何完成“路由功能”的；

（4）分析Android系统中默认的“路由策略”。

其中AudioPolicyService的“路由实现”因为与AudioTrack关系紧密，我们特地把它们结合起来进行讲解。

13.4.2　AudioPolicyService的启动过程

还记得前面我们在分析AudioFlinger的启动时，曾经看到过AudioPolicyService的“影子”吗？没错，它和AudioFlinger是驻留在同一个进程中的。如下所示：

```
/*frameworks/av/media/mediaserver/Main_mediaserver.cpp*/
int main(int argc, char** argv)
```

```
{       …
        AudioFlinger::instantiate();
        …
        AudioPolicyService::instantiate();
        ProcessState::self()->startThreadPool();
        IPCThreadState::self()->joinThreadPool();
}
```

因而从理论上讲，AudioFlinger和AudioPolicyService是可以直接进行函数调用的。不过，实际上它们仍然采用标准的Binder接口进行通信（同一进程中的Binder通信细节，读者可以参考本书Binder章节的描述）。

AudioPolicyService的启动方式和AudioFlinger也类似，这里不再赘述，直接来看它的构造函数：

```
AudioPolicyService::AudioPolicyService()
   : BnAudioPolicyService() , mpAudioPolicyDev(NULL) , mpAudioPol
{
    char value[PROPERTY_VALUE_MAX];
    const struct hw_module_t *module;
    int forced_val;
    int rc;
    …
    rc = hw_get_module(AUDIO_POLICY_HARDWARE_MODULE_ID, &module);
    …
    rc = audio_policy_dev_open(module, &mpAudioPolicyDev);//Step
    …
    rc = mpAudioPolicyDev->create_audio_policy(mpAudioPolicyDev,
                                              &mpAudioPolicy);//S
    …
    rc = mpAudioPolicy->init_check(mpAudioPolicy); //Step 4.初始化
    …
    //Step 5.加载音频效果配置文件
    if (access(AUDIO_EFFECT_VENDOR_CONFIG_FILE, R_OK) == 0) {
           loadPreProcessorConfig(AUDIO_EFFECT_VENDOR_CONFIG_FILE
    } else if (access(AUDIO_EFFECT_DEFAULT_CONFIG_FILE, R_OK) ==
           loadPreProcessorConfig(AUDIO_EFFECT_DEFAULT_CONFIG_FIL
    }
}
```

我们将上述代码段分为5个步骤来讲解。

Step1@AudioPolicyService::AudioPolicyService。得到Audio

Policy的hw_module_t，原生态系统中Audio Policy的实现有两个地方，即Audio_policy.c和Audio_policy_hal.cpp，默认情况下系统选择的是后者（对应的库是libaudiopolicy_legacy）。

Step2@AudioPolicyService::AudioPolicyService。通过上一步得到的hw_module_t打开Audio Policy设备（这并不是一个传统意义的硬件设备，而是把Policy虚拟成一种设备。这种实现方式让开发商在制定自己的音频策略时多了不少灵活性）。原生态代码中audio_policy_dev_open调用的是legacy_ap_dev_open@Audio_policy_hal.cpp，最终生成的Policy Device是legacy_ap_device。

Step3@AudioPolicyService::AudioPolicyService。通过上述的Audio Policy设备来产生一个策略，其对应的具体实现方法是create_legacy_ap@Audio_policy_hal.cpp。这个函数首先生成一个legacy_audio_policy@Audio_policy_hal.cpp对象，而mpAudioPolicy对应的则是legacy_audio_policy::policy。除此之外，legacy_audio_policy还包含如下重要的成员变量：

```
struct legacy_audio_policy {
      struct audio_policy policy;
      void *service;
      struct audio_policy_service_ops *aps_ops;
      AudioPolicyCompatClient *service_client;
      AudioPolicyInterface *apm;
};
```

其中aps_ops是由AudioPolicyService提供的函数指针（aps_ops），其中的函数集合是AudioPolicyService与外界沟通的接口，后面还会经常遇到。

最后一个apm是AudioPolicyManager的简写，AudioPolicyInterface是其基类。而apm在原生态实现中是一个AudioPolicyManagerDefault对象，它是在create_legacy_ap中创建的：

```
static int create_legacy_ap(const struct audio_policy_device *dev
                            struct audio_policy_service_ops *aps_
                            void *service,
                            struct audio_policy **ap)
{
    struct legacy_audio_policy *lap;
```

```
    …
    lap->apm = createAudioPolicyManager(lap->service_client);
…}
```

函数createAudioPolicyManager默认情况下对应的是AudioPolicyManagerDefault.cpp中的实现，所以它将返回一个AudioPolicyManagerDefault。

是不是觉得“Policy”相关的类越来越多了，那为什么需要这么多类呢？我们先来看一下它们之间的关系，如图13-18所示。

看起来很复杂，其实概括一下就以下几点。

- AudioPolicyService持有的只是一个类似于接口类的对象，即audio_policy。换句话说，AudioPolicyService是一个“母体”，而audio_policy则是一个符合要求的插件。插件与壳之间的接口是固定不变的，而内部实现却可以根据厂商自己的需求来做。
- 我们知道，audio_policy实际上是一个C语言中的struct数据类型，内部包含了各种函数指针，如get_output，start_output等。这些函数指针在初始化时，需要指向具体的函数实现，这就对应Audio_policy_hal中的ap_get_output，ap_start_output等。
- 上面提到的各数据类型更多的只是一个“壳”，而真正的实现者是AudioPolicyManager。与此相关的又有三个类：AudioPolicyInterface是它们的基类，AudioPolicyManagerBase实现了一些基础的策略，而AudioPolicyManagerDefault则是最终的实现类。除了AudioPolicyService，后面这两个类也是我们研究Audio Policy的重点。

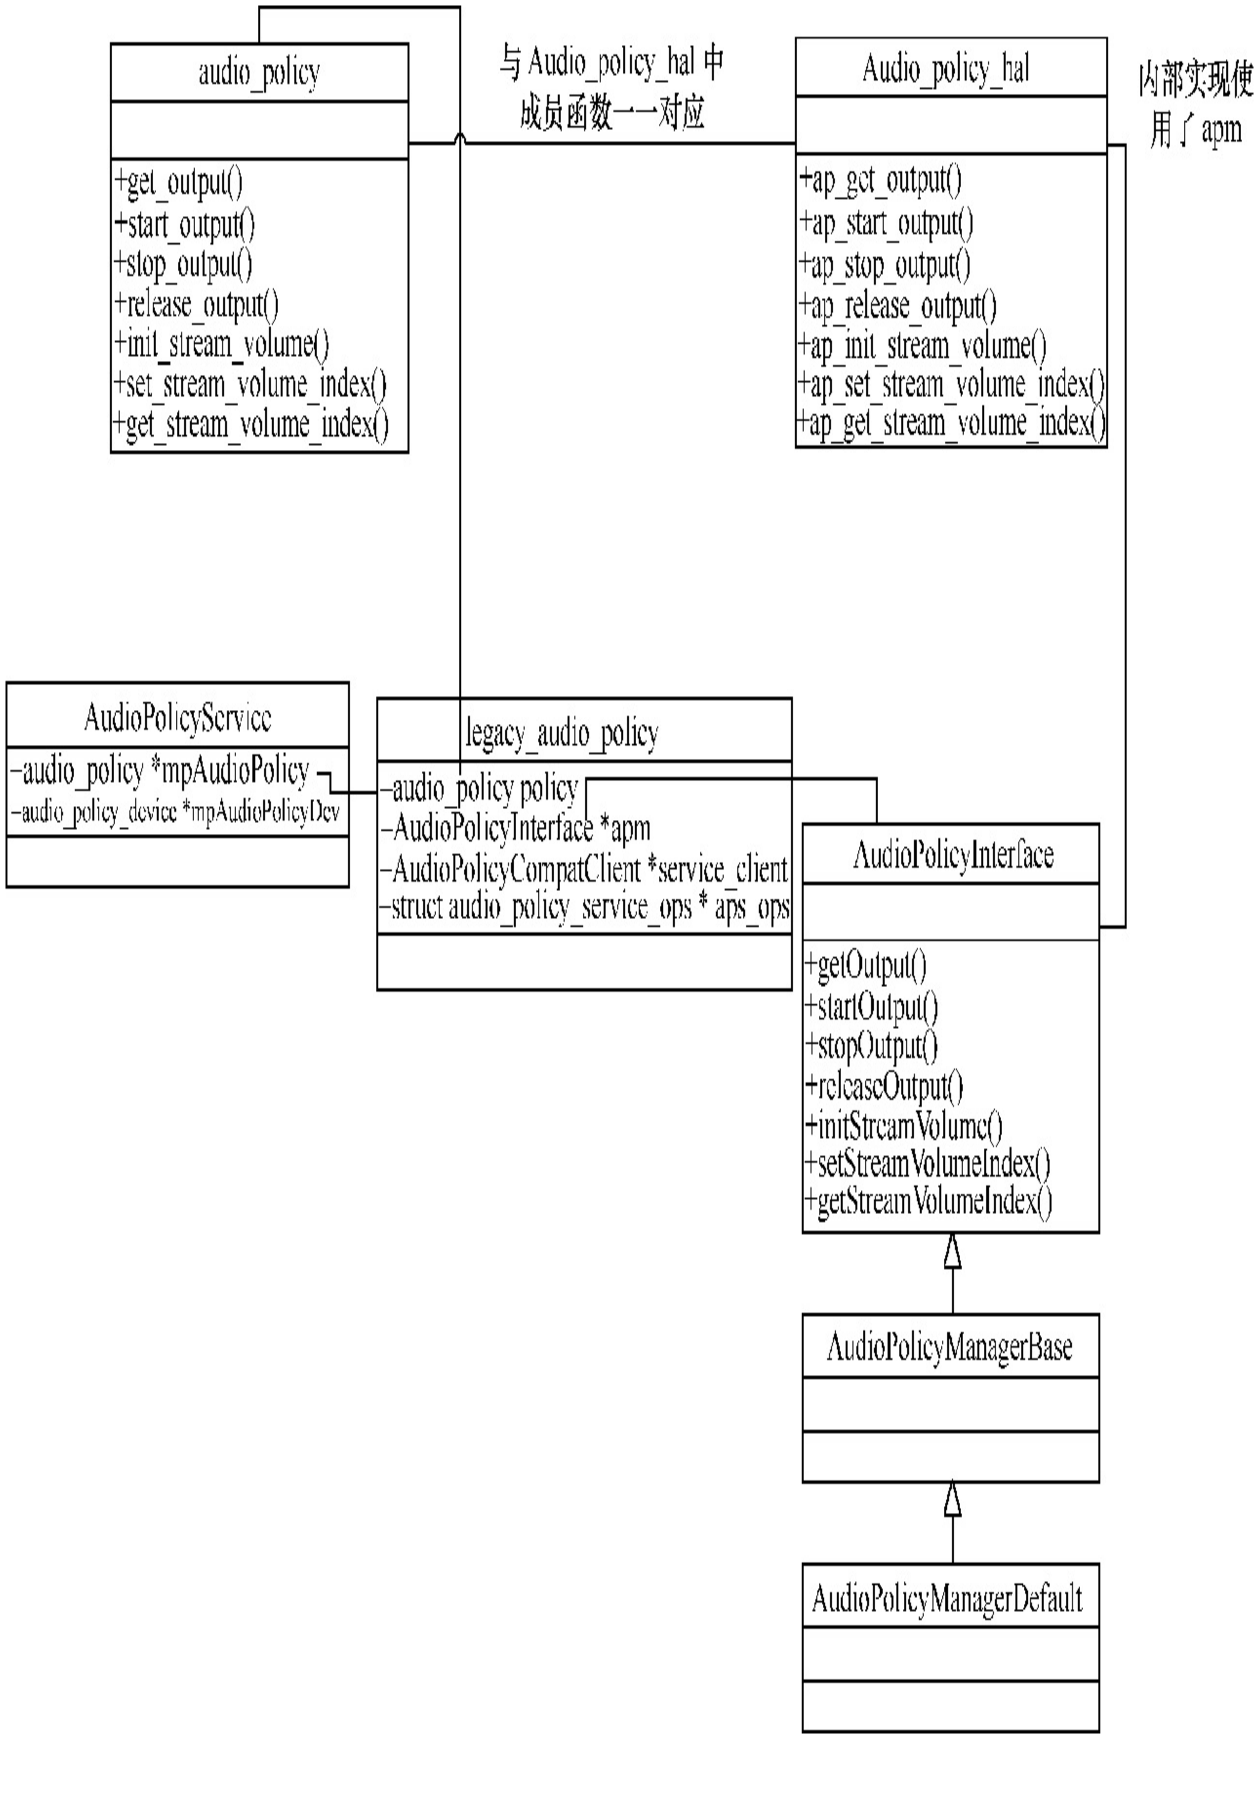
audio_policy
+get_output()
+start_output()
+stop_output()
+release_output()
+init_stream_volume()
+set_stream_volume_index()
+get_stream_volume_index()
与Audio_policy_hal中
成员函数一一对应
Audio_policy_hal
+ap_get_output()
+ap_start_output()
+ap_stop_output()
+ap_release_output()
+ap_init_stream_volume()
+ap_set_stream_volume_index()
+ap_get_stream_volume_index()
内部实现使
用了apm
AudioPolicyService
-audio_policy *mpAudioPolicy
-audio_policy_device *mpAudioPolicyDev
legacy_audio_policy
-audio_policy policy
-AudioPolicyInterface *apm
-AudioPolicyCompatClient *service_client
-struct audio_policy_service_ops * aps_ops
AudioPolicyInterface
+getOutput()
+startOutput()
+stopOutput()
+releaseOutput()
+initStreamVolume()
+setStreamVolumeIndex()
+getStreamVolumeIndex()
AudioPolicyManagerBase
AudioPolicyManagerDefault

▲图13-18　Audio Policy相关类的关系图

Step4@AudioPolicyService::AudioPolicyService。进行初始化检测，原生态的实现直接返回0。

Step5@AudioPolicyService::AudioPolicyService。加载音频效果文件（如果存在的话），文件路径如下：

```
AUDIO_EFFECT_DEFAULT_CONFIG_FILE "/system/etc/audio_effects.conf"
AUDIO_EFFECT_VENDOR_CONFIG_FILE "/vendor/etc/audio_effects.conf"
```

这样AudioPolicyService就完成了构造过程，而且它在ServiceManager中的注册名称为"media.audio_policy"。其中包含的mpAudioPolicy变量是实际的策略制定者，而它也是通过HAL层的库来创建的。换句话说，是根据硬件厂商自己的“意愿”来制定的策略。

13.4.3　AudioPolicyService与音频设备

在AudioFlinger的“设备管理”小节，我们曾简单提及AudioPolicyService将通过解析配置文件来加载当前系统中的音频设备。具体而言，当AudioPolicyService构造时创建了一个AudioPolicy Device(mpAudioPolicyDev)并由此打开一个AudioPolicy(mpAudioPolicy)——这个Policy默认情况下的实现是legacy_audio_policy::policy（数据类型audio_policy）；同时，legacy_audio_policy还包含了一个AudioPolicyInterface成员变量，它会被初始化为一个AudioPolicyManagerDefault，这些知识点都是我们在前一个小节分析过的。

那么，AudioPolicyService在什么时候会通过AudioFlinger去加载音频设备呢？

除了后期的动态添加外，另外一个重要途径就是通过AudioPolicyManagerDefault的父类，即AudioPolicyManagerBase的构造函数来加载音频设备：

```
AudioPolicyManagerBase::AudioPolicyManagerBase(AudioPolicyClientI
Interface)…
{   mpClientInterface = clientInterface;
```

```
    …
    if (loadAudioPolicyConfig(AUDIO_POLICY_VENDOR_CONFIG_FILE) !=
        if (loadAudioPolicyConfig(AUDIO_POLICY_CONFIG_FILE) != NO
             defaultAudioPolicyConfig();
        }
    }
    for (size_t i = 0; i < mHwModules.size(); i++) {
        mHwModules[i]->mHandle = mpClientInterface->loadHwModule(
        if (mHwModules[i]->mHandle == 0) {
            continue;
        }
        for (size_t j = 0; j < mHwModules[i]->mOutputProfiles.siz
        {
           const IOProfile *outProfile = mHwModules[i]->mOutputPr
           if (outProfile->mSupportedDevices & mAttachedOutputDev
               AudioOutputDescriptor *outputDesc = new AudioOutpu
               outputDesc->mDevice = (audio_devices_t)(mDefaultOu
                                                     outProfile->m
           audio_io_handle_t output = mpClientInterface->openOutp
     …
}
```

不同的Android产品在音频硬件的设计上通常是有差异的——利用配置文件的形式（audio_policy.conf）来描述产品中所包含的具体音频设备，为我们进行定制开发提供了便捷的实现。这个文件的存放路径有两处：

```
#define AUDIO_POLICY_VENDOR_CONFIG_FILE "/vendor/etc/audio_policy
#define AUDIO_POLICY_CONFIG_FILE "/system/etc/audio_policy.conf"
```

如果audio_policy.conf不存在的话，则系统将使用默认的配置，具体就在defaultAudioPolicy Config中。通过配置文件可以读取到如下信息：

- 有哪些audio interface，如有没有“primary”“a2dp”“usb”；
- 每个audio interface的属性，如支持的sampling_rates，formats支持哪些device等。这些属性是在loadOutput@AudioPolicyManagerBase中读取的，并存储到HwModule-> mOutputProfiles中。每一个audio interface下可能有若干个output和input，而每个output/input下又具体描述了它们所支持的若干属性，其关系如图13-19所示。

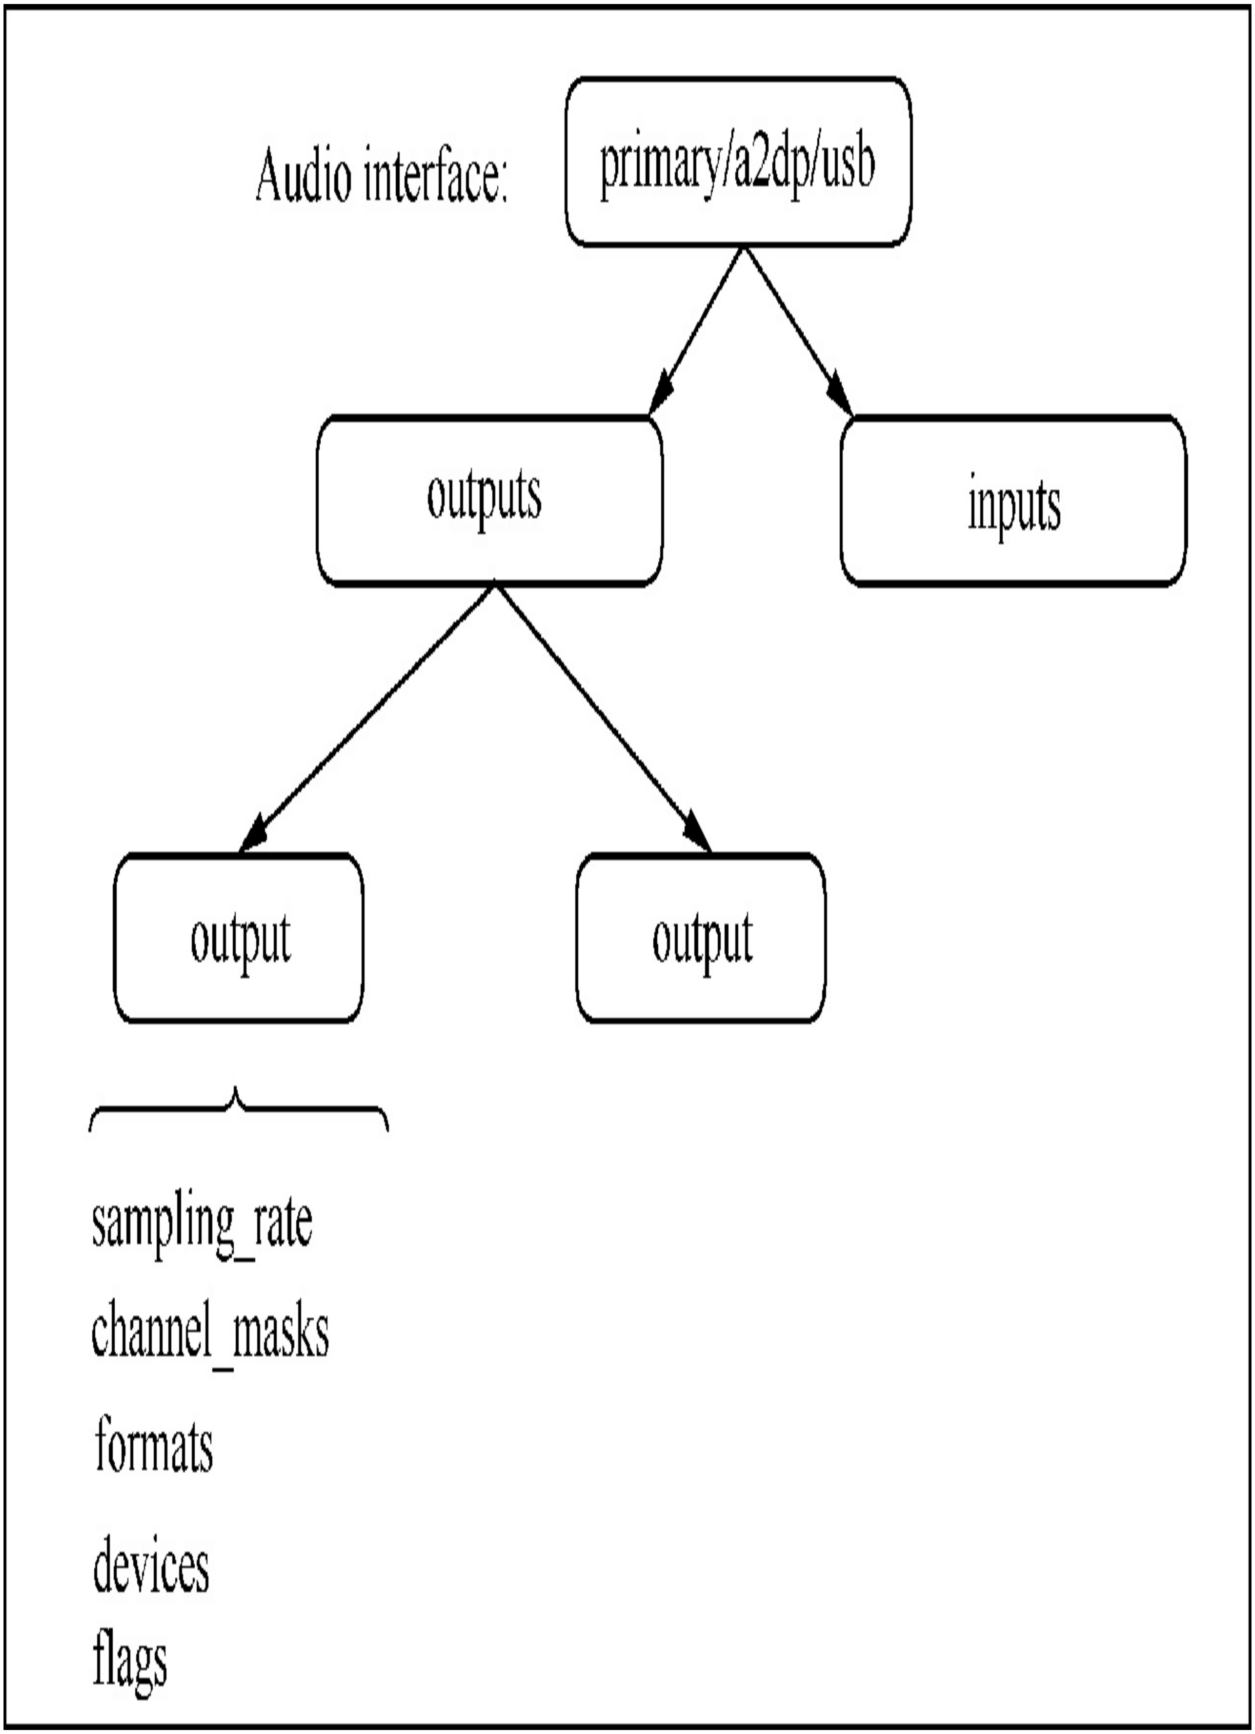
Audio interface:
primary/a2dp/usb
outputs
inputs
output
output
sampling_rate
channel_masks
formats
devices
flags

▲图13-19　audio_policy.conf中各元素关系图

读者可以自己打开一个audio_policy.conf来具体了解这个文件的编写格式，我们这里就不深入讲解了。

读取了相关配置后，接下来就要打开这些设备。我们知道AudioPolicyService只是策略的制定者，而非执行者。那么，由谁来完成这些具体的打开工作呢？没错，一定是AudioFlinger。可以看到上述函数段中有一个mpClientInterface变量，它是否和AudioFlinger有联系？先来分析这个变量的来源。

很明显，mpClientInterface在AudioPolicyManagerBase构造函数的第一行进行了初始化。再回溯追踪，不难发现它的根源在AudioPolicyService的构造函数中，对应的代码语句如下：

```
rc = mpAudioPolicyDev->create_audio_policy(mpAudioPolicyDev, &aps
```

在这个场景下，函数create_audio_policy对应的是create_legacy_ap，并将传入的aps_ops组装到一个AudioPolicyCompatClient对象中，即mpClientInterface所指向的那个对象。

换句话说，mpClientInterface->loadHwModule实际上调用的就是aps_ops->loadHwModule。即：

```
static audio_module_handle_t aps_load_hw_module(void *service,con
{
    sp<IAudioFlinger> af = AudioSystem::get_audio_flinger();
    …
    return af->loadHwModule(name);
}
```

AudioFlinger终于出现了——同样的情况也适用于mpClientInterface->openOutput。具体代码如下：

```
static audio_io_handle_t aps_open_output(…)
{
    sp<IAudioFlinger> af = AudioSystem::get_audio_flinger();
    …
    return af->openOutput((audio_module_handle_t)0, pDevices, pSa
    pChannelMask,pLatencyMs, flags);
```

}

再回到AudioPolicyManagerBase的构造函数中，for循环的目标有两个。

- 利用loadHwModule来加载从audio_policy.conf中解析出的Audio Interface，即mHwModules数组中的元素。
- 利用openOutput来打开各Audio Interface中包含的所有Output。

关于AudioFlinger中上述这两个函数的实现，我们在前一个小节已经分析过，这里终于把它们“串”起来了。通过AudioPolicyManagerBase，AudioPolicyService解析出了设备中的音频配置文件，并利用AudioFlinger提供的接口完成了整个音频系统的部署，从而为后续上层应用使用音频设备提供了底层支撑。

下一节我们就可以看到上层应用具体如何使用这一框架来回放音频。

13.5　音频流的回放——AudioTrack

13.5.1　AudioTrack应用实例

虽然很多人对MediaPlayer并不陌生，但了解AudioTrack的估计就比较少了。这是因为MediaPlayer提供了更完整的封装和状态控制，使得我们用很少的代码就可以实现一个简单的音乐播放器。相比MediaPlayer，AudioTrack则更为精练、高效（实际上MediaPlayerService实现音频回放就是使用了AudioTrack）。

AudioTrack被用于PCM音频流的回放，在数据传送上有两种方式。

- 调用write(byte[],int,int)或write(short[],int,int)把音频数据“push”到AudioTrack中。
- 与之相对的，当然就是“pull”类型的数据获取方式，即“数据接收方”主动索取的过程，如图13-20所示。

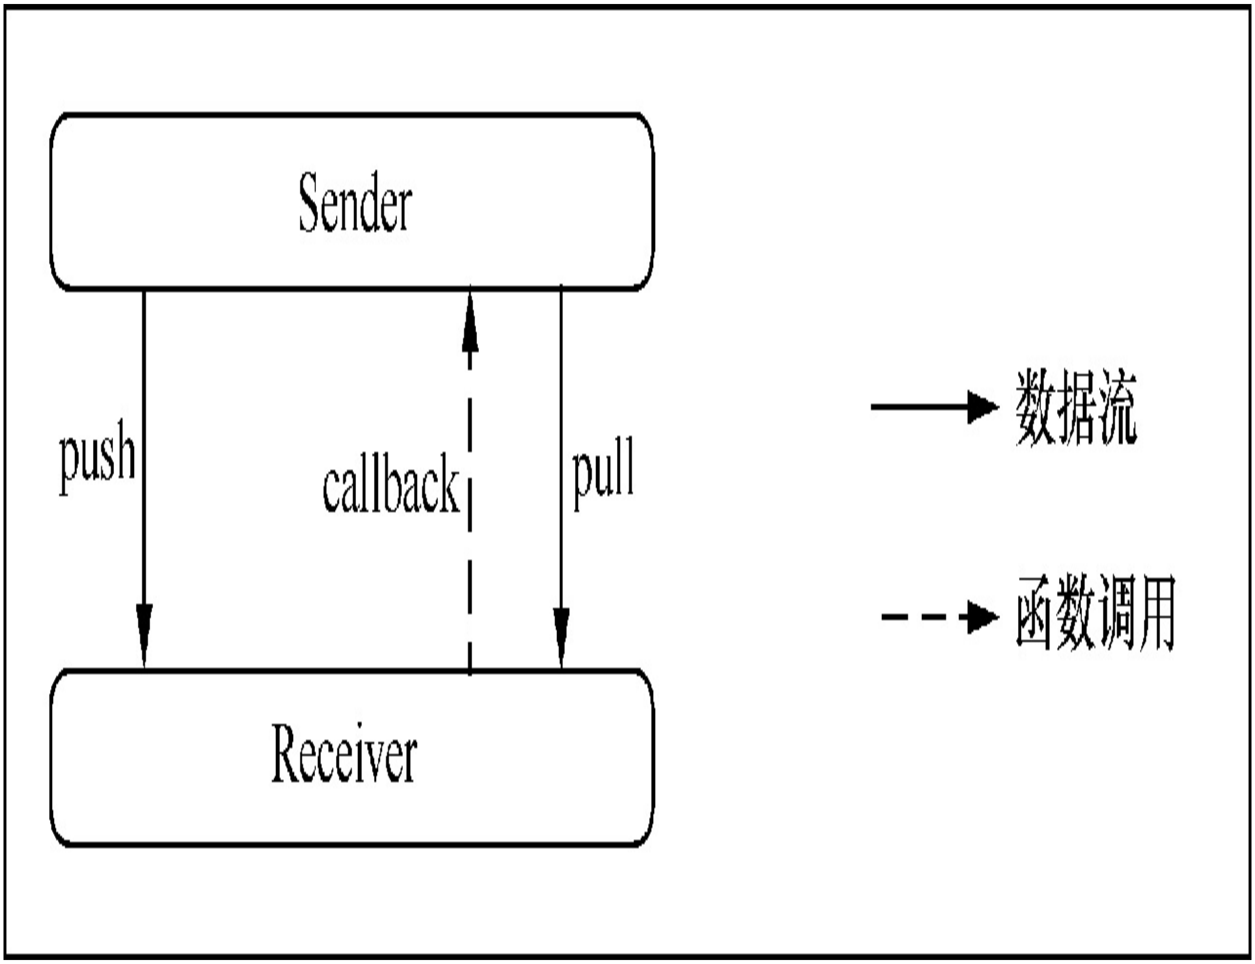

▲图13-20 “push”和“pull”两种数据传送模式

除此之外，AudioTrack还同时支持static和streaming两种数据模式。

- static

静态就是指数据一次性交付给接收方。其好处是简单高效，只需进行一次操作就完成了所有数据的传递；缺点当然也很明显——对于数据量较大的音频回放，它是无法胜任的。因而这种模式通常只适用于铃声、系统提醒等对内存要求小的播放操作。

- streaming

流模式和基于网络的音频流回放类似，即音频数据严格按照要求不断地传递给接收方，直到结束。理论上它适用于任何音频播放的场景，

不过我们通常会在以下情况中优先考虑采用。

- 音频文件较大时。
- 音频属性要求高，如采样率高、深度大的数据。
- 音频数据是实时产生的，这种情况就只能用流模式了。

下面我们选取源码工程中的MediaAudioTrackTest.java范例来讲解AudioTrack的典型应用，具体如下所示：

```
public void testSetStereoVolumeMax() throws Exception {
    final String TEST_NAME = "testSetStereoVolumeMax";
    final int TEST_SR = 22050;
    final int TEST_CONF = AudioFormat.CHANNEL_OUT_STEREO;
    final int TEST_FORMAT = AudioFormat.ENCODING_PCM_16BIT;
    final int TEST_MODE = AudioTrack.MODE_STREAM;
    final int TEST_STREAM_TYPE = AudioManager.STREAM_MUSIC;
    /*Step 1.计算最小缓冲区大小*/
    int minBuffSize = AudioTrack.getMinBufferSize(TEST_SR, TE
    /*Step 2.生成AudioTrack对象*/
    AudioTrack track = new AudioTrack(TEST_STREAM_TYPE, TEST_
                                  TEST_FORMAT, minBuffSiz
    byte data[] = new byte[minBuffSize/2];
    //--------    test        --------------
    track.write(data, 0, data.length);//写入音频数据
    track.write(data, 0, data.length);
    track.play();//开始播放音频
    float maxVol = AudioTrack.getMaxVolume();//获取最大音量值
    assertTrue(TEST_NAME, track.setStereoVolume(maxVol, maxVo
    //-------- tear down      --------------
    track.release();
}
```

上述这个TestCase用于测试立体声左右声道的最大音量，范例中涉及的AudioTrack的常规操作都用高显标示出来了（顺便提一下，关于Android自动化测试的更多描述，可以参考本书最后一个篇章）。

包括如下几个步骤：

Step1@testSetStereoVolumeMax。函数getMinBufferSize的字面意思是获取最小的buffer大小，这个buffer将用于后面AudioTrack的构造函数。它是AudioTrack可以正常使用的一个最低保障——如果音频文件

本身要求较高，官方建议最好采用比MinBufferSize更大的数值。这个函数的具体实现如下（分段阅读）：

```
static public int getMinBufferSize(int sampleRateInHz, int channe
            int channelCount = 0;
            switch(channelConfig) {
            case AudioFormat.CHANNEL_OUT_MONO:
            case AudioFormat.CHANNEL_CONFIGURATION_MONO:
                    channelCount = 1;
                    break;
            case AudioFormat.CHANNEL_OUT_STEREO:
            case AudioFormat.CHANNEL_CONFIGURATION_STEREO:
                    channelCount = 2;
                    break;
            default:
                …
            }
```

首先得出音频的声道数属性。由channelCount这个变量的处理过程可知目前版本的系统最多只支持双声道：

```
        if ((audioFormat != AudioFormat.ENCODING_PCM_16BIT)
             && (audioFormat != AudioFormat.ENCODING_PCM_8BIT)) {
           return AudioTrack.ERROR_BAD_VALUE;
        }
```

紧接着检查音频采样深度，只支持8bit和16bit两种：

```
        if ((sampleRateInHz < SAMPLE_RATE_HZ_MIN)||(sampleRateInH
        {
           loge("getMinBufferSize(): " + sampleRateInHz +"Hz is n
            return AudioTrack.ERROR_BAD_VALUE;
        }
```

最后还需要检查采样频率。其支持的范围并不算宽，但对大部分应用场合都是适用的，即4k(SAMPLE_RATE_HZ_MIN)-48Khz(SAMPLE_RATE_HZ_MAX)：

```
        int size = native_get_min_buff_size(sampleRateInHz, chann
        …
    }//getMinBufferSize结束
```

也就是说，最小的buffer大小取决于采样率、声道数和采样深度这3个属性。那么，具体是如何计算的呢？我们接着看看native层的代码

实现:

```
frameworks/base/core/jni/android_media_AudioTrack.cpp
static jint android_media_AudioTrack_get_min_buff_size(JNIEnv *en
                               jint sampleRateInHertz, jint nbCha
    int frameCount = 0;
    if (AudioTrack::getMinFrameCount(&frameCount, AUDIO_STREAM_DE
                               sampleRateInHertz) != NO_ERROR) {
        return -1;
    }
    return frameCount * nbChannels * (audioFormat == javaAudioTra
}
```

这里又调用了getMinFrameCount——这个函数用于确定至少需要多少Frame才能保证音频的正常播放。那么，Frame代表了什么意思呢？大家可以类比一下视频中“帧”的概念——它代表了某个时间点的一幅图像。这里的Frame也相似，它指的是某个特定时间点时的音频数据量，所以android_media_AudioTrack_get_min_buff_size中最后使用的计算公式就是:

最小缓冲区大小=至少需要多少帧*每帧数据量

= frameCount * nbChannels * (audioFormat == javaAudioTrackFields.PCM16 ? 2 : 1);

公式中frameCount就是所需要的帧数，每一帧的数据量又等于:

Channel数*每个Channel数据量=nbChannels * (audioFormat == javaAudioTrackFields.PCM16 ? 2 : 1)

然后函数层层返回直到getMinBufferSize，我们就得到了能保障AudioTrack正常工作的最小缓冲区大小。

Step2@testSetStereoVolumeMax。创建AudioTrack实例。

有了minBufferSize后，我们就可以创建一个AudioTrack对象了。它的构造函数原型是:

```
public AudioTrack (int streamType, int sampleRateInHz, int channe
```

除了倒数第二个参数是计算出来的，其他入参在这个TestCase中都

是直接指定的。比如streamType是STREAM_MUSIC，sampleRateInHz是22050等。如果我们使用AudioTrack来编写一个音乐播放器，那么这些参数都是需要通过分析音频文件得出来的。幸运的是Android系统提供了更加易用的MediaPlayer，使得开发者不需要理会这些琐碎细节。

创建AudioTrack的一个重要任务就是和AudioFlinger建立联系，它是由native层的代码来实现的：

```
    public AudioTrack(int streamType, int sampleRateInHz, int cha
          int bufferSizeInBytes, int mode, int sessionId)
    throws IllegalArgumentException {
        …
        int initResult = native_setup(new WeakReference<AudioTrac
               mStreamType, mSampleRate, mChannels, mAudioFormat,
               mNativeBufferSizeInBytes, mDataLoadMode, session);
        …
    }
```

这里调用了native_setup来创建一个本地的AudioTrack对象。如下所示：

```
/*frameworks/base/core/jni/android_media_AudioTrack.cpp*/
static intandroid_media_AudioTrack_native_setup(JNIEnv *env, jobj
      jint streamType, jint sampleRateInHertz, jint javaChannelMa
      jint audioFormat, jint buffSizeInBytes, jint memoryMode, ji
{
    …
    sp<AudioTrack> lpTrack = new AudioTrack();
    …
    AudioTrackJniStorage* lpJniStorage = new AudioTrackJniStorage
```

生成一个Storage对象，直觉告诉我们这可能是存储音频数据的地方，后面再详细分析：

```
    …
    if (memoryMode == javaAudioTrackFields.MODE_STREAM) {
           lpTrack->set(…
           audioCallback, //回调函数
           &(lpJniStorage->mCallbackData),//回调数据
           0,
           0,// shared mem
           true,// thread can call Java
           sessionId);// audio session ID
    } else if (memoryMode == javaAudioTrackFields.MODE_STATIC) {
```

```
        …
        lpTrack->set(…
        audioCallback,&(lpJniStorage->mCallbackData), 0,
        lpJniStorage->mMemBase,// shared mem
               true,// thread can call Java
               sessionId);// audio session ID
    }
…//native_setup结束
```

函数native_setup首先生成了一个AudioTrack(native)对象，然后进行各种属性的计算，最后调用set函数为AudioTrack设置这些属性——其中需要特别注意的是两种内存模式（MODE_STATIC和MODE_STREAM）下处理手法的差异。对于静态方式，set函数的倒数第三个参数是lpJniStorage->mMemBase；而STREAM类型时这个参数则为null(0)。

到目前为止我们还没有看到AudioTrack与AudioFlinger有交互的地方，看来谜底应该就在这个set函数中了（分段阅读）：

```
status_t AudioTrack::set(…callback_t cbf, void* user, int notific
const sp<IMemory>& sharedBuffer, bool threadCanCallJava, int sess
{…
    AutoMutex lock(mLock);
    …
    if (streamType == AUDIO_STREAM_DEFAULT) {
        streamType = AUDIO_STREAM_MUSIC;
    }
```

当AudioTrack没有特别指明streamType时，程序会为它设置一个默认的值，即AUDIO_STREAM_MUSIC：

```
    …
    if (format == AUDIO_FORMAT_DEFAULT) {//默认的采样深度值
        format = AUDIO_FORMAT_PCM_16_BIT;
    }
    if (channelMask == 0) {//默认声道数
        channelMask = AUDIO_CHANNEL_OUT_STEREO;
    }
```

采样深度和声道数的默认值分别为16bit和立体声：

```
    …
    if (format == AUDIO_FORMAT_PCM_8_BIT && sharedBuffer != 0) {
           ALOGE("8-bit data in shared memory is not supported");
```

```
        return BAD_VALUE;
    }
```

当sharedBuffer!=0时表明是STATIC模式。也就是说，静态数据模式下只支持16bit采样深度，否则就会报错并直接返回，这点要特别注意：

```
    …
audio_io_handle_t output = AudioSystem::getOutput(streamType, sam
                                                  channelMask,fla
```

通过上述的有效性检查后，AudioTrack接着就可以使用底层的音频服务了。那么，是直接调用AudioFlinger服务提供的接口吗？理论上这样做也是可以的，但Android系统考虑得更细致，它在AudioTrack与底层服务间又提供了AudioSystem和AudioService。前者同时提供了Java和Native两层的接口实现；而AudioService则只有Native层的实现。这样就降低了使用者（AudioTrack）与底层服务（AudioPolicyService、AudioFlinger等）间的耦合。换句话说，不同版本的Android音频系统通常改动很大，但只要AudioSystem和AudioService向上的接口不变，那么AudioTrack就不需要做任何修改。

上面的getOutput函数是由AudioSystem提供的，不过可以猜测到其内部只是做了些简单的中转工作，最终还是得由AudioPolicyService/AudioFlinger来实现具体功能。这个getOutput会在当前系统中寻找最适合AudioTrack的Audio Interface以及Output输出（即AudioFlinger中通过openOutput打开的通道），然后AudioTrack会向这个Output申请一个Track：

```
    …
    mVolume[LEFT] = 1.0f;
    mVolume[RIGHT] = 1.0f; /*左右声道的初始音量值都设置成最大。AudioTra
                             在这里赋值，源代码略*/
    …
    if (cbf != NULL) {
        mAudioTrackThread = new AudioTrackThread(*this, threadCan
        mAudioTrackThread->run("AudioTrack", ANDROID_PRIORITY_AUD
    }
    status_t status = createTrack_l(…sharedBuffer, output);
    …
}//AudioTrack::set函数结束
```

因为cbf不为空，所以这里会启动一个AudioTrack线程。

AudioTrackThread需要实现两个核心功能。

- AudioTrack与AudioFlinger间的数据传输

我们知道AudioFlinger启动了一个线程专门用于接收客户端的音频数据；同理，客户端也需要一个工作线程来“不断”地传送音频数据。

- 用于报告数据传输状态

音频传输过程中可能会有多种事件发生，如underrun。此时需要不断回传状态给使用者进行相应处理。AudioTrack中保存了（即全局变量mCbf）一个callback_t类型的回调函数，用于事件发生时进行回传。

callback_t为上层应用处理事件提供了一个入口。包括：

```
EVENT_MORE_DATA = 0,  /*请求写入更多数据*/
EVENT_UNDERRUN = 1,  /*音频传输发生了underrun问题*/
EVENT_LOOP_END = 2,   /*到达loop end，此时如果loop count不为空的话
将从loop start重新开始回放*/
EVENT_MARKER = 3，    /*Playback head在指定的位置，参考setMarkerPosi
EVENT_NEW_POS = 4，/*Playback head在一个新的位置，参考setPositionUpda
EVENT_BUFFER_END = 5 /*Playback head在buffer末尾*/
```

AudioTrack在AudioFlinger内部是以Track类来管理的。不过因为它们之间是跨进程的关系，自然需要一个“桥梁”来维护，这个沟通的媒介是IaudioTrack（有点类似于显示系统中的Iwindow）。函数createTrack_l除了为AudioTrack在AudioFlinger中申请一个Track外，还会建立两者间的IAudioTrack桥梁：

```
status_t AudioTrack::createTrack_l(
       audio_stream_type_t streamType,uint32_t sampleRate, audio_
       channelMask,
       int frameCount, audio_output_flags_t flags, const sp<IMemo
       audio_io_handle_t output)
{
    const sp<IAudioFlinger>& audioFlinger = AudioSystem::get_audi
```

获得AudioFlinger服务，还记得上一小节的介绍吗？AudioFlinger会在ServiceManager中注册，并以“media.audio_flinger”为服务名：

```
    …
    IAudioFlinger::track_flags_t trackFlags = IAudioFlinger::TRAC
    …
    sp<IAudioTrack> track = audioFlinger->createTrack(getpid(),st
                          format,channelMask, frameCount, trackF
                         output, tid, &mSessionId, &status);
//未完待续…
```

利用AudioFlinger创建一个IAudioTrack，这是它与AudioTrack之间的跨进程通道。除此之外，AudioFlinger还做了什么？我们深入AudioFlinger进行分析：

```
sp<IAudioTrack> AudioFlinger::createTrack(…const sp<IMemory>& sha
handle_t output,
      pid_t tid, int *sessionId, status_t *status)
{
    sp<PlaybackThread::Track>track;
    sp<TrackHandle> trackHandle;
    …
    PlaybackThread *thread =checkPlaybackThread_l(output);
    PlaybackThread *effectThread = NULL;
    …
    track = thread->createTrack_l(client, streamType, sampleRate,
             channelMask, frameCount, sharedBuffer, lSessionId, f
    …
    if (lStatus == NO_ERROR) {
        trackHandle = new TrackHandle(track);
    } else {
        client.clear();
        track.clear();
    }
    return trackHandle;
}
```

我们只留下createTrack中最重要的几个步骤，即：

- AudioFlinger::checkPlaybackThread_l

在AudioFlinger::openOutput时，产生了全局唯一的audio_io_handle_t值，这个值是与PlaybackThread相对应的，它作为mPlaybackThreads键值对的key值存在。

当AudioTrack调用createTrack时，需要传入这个全局标记值，checkPlaybackThread_l借此找到匹配的PlaybackThread。

- PlaybackThread::createTrack_l

找到匹配的PlaybackThread后，还需要在其内部创建一个PlaybackThread::Track对象（所有Track都由PlaybackThread::mTracks全局变量管理），这些工作由PlaybackThread::createTrack_l完成。我们以图13-21来表示它们之间的关系。

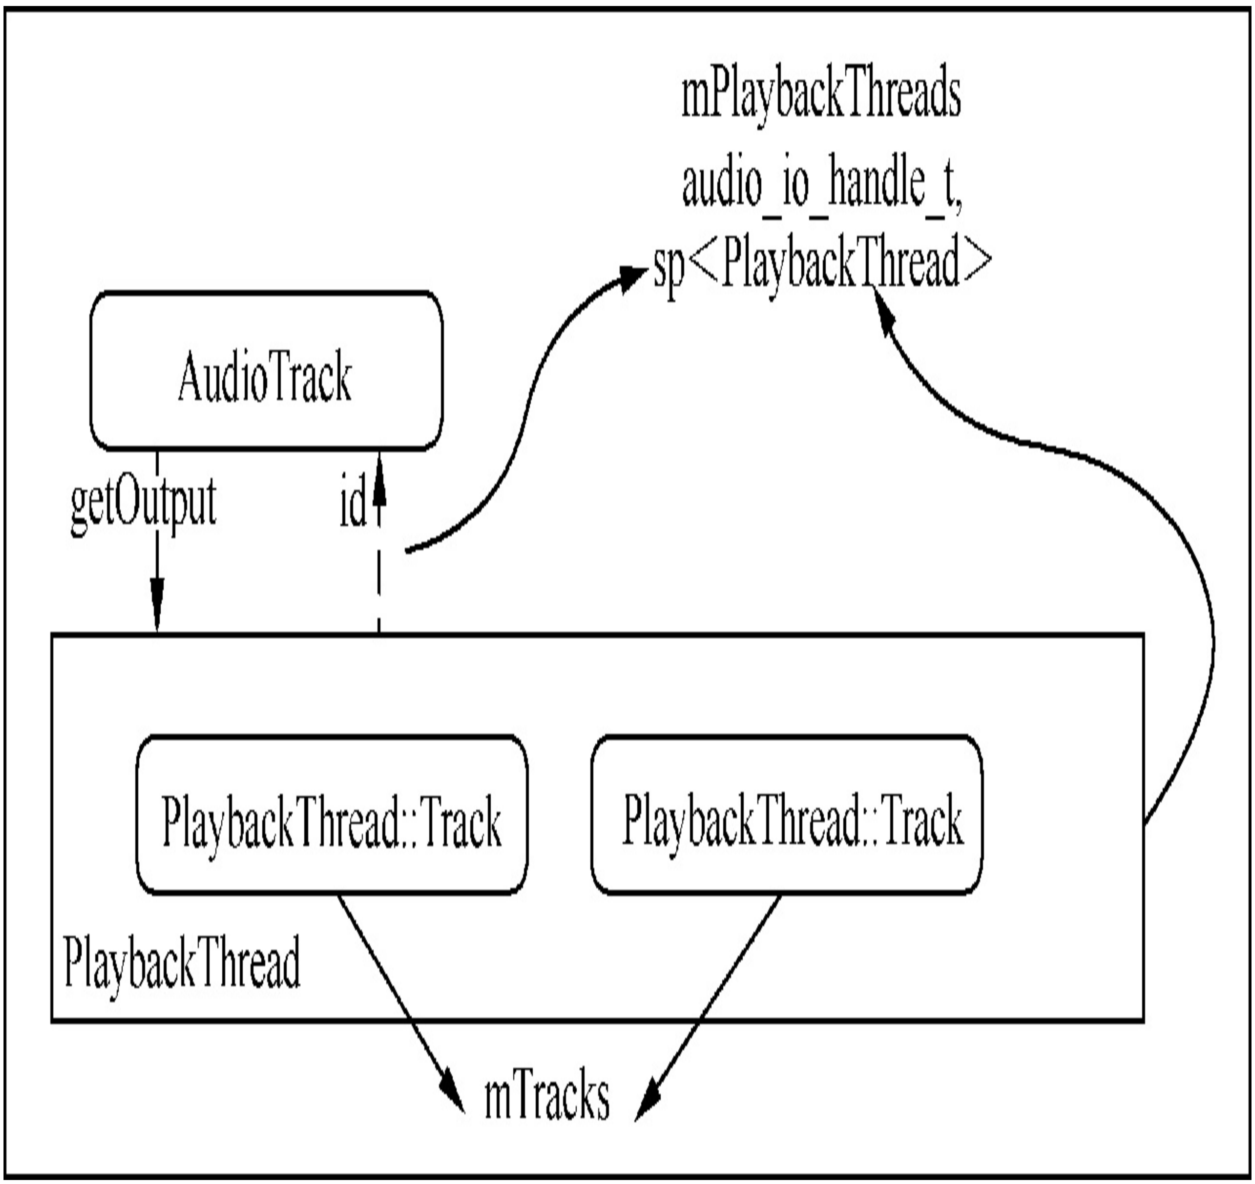

▲图13-21　PlaybackThread中对Track的管理

- new TrackHandle

TrackHandle实际上就是IAudioTrack，后续AudioTrack将利用这个Binder服务来调用getCblk等接口。

我们接着前面AudioTrack::createTrack_l中“未完待续”的部分往下看：

```
    …
    sp<IMemory> cblk = track->getCblk();
    …
    mAudioTrack = track;
    mCblkMemory = cblk;
    mCblk = static_cast<audio_track_cblk_t*>(cblk->pointer());
    …
    if (sharedBuffer == 0) {
        mCblk->buffers = (char*)mCblk + sizeof(audio_track_cblk_t
    } else {
        mCblk->buffers = sharedBuffer->pointer();
        mCblk->stepUser(mCblk->frameCount);
    }
    …
    return NO_ERROR;
}
```

事实上当PlaybackThread创建一个PlaybackThread::Track对象时，所需的缓冲区空间就已经分配了。这块空间是可以跨进程共享的，所以AudioTrack可以通过track->getCblk()来获取。看起来很简单的一句代码，其中却涉及很多细节，我们会在后面的数据流小节做统一分析。

到目前为止，AudioTrack已经可以通过IaudioTrack（即上面代码段中的track变量）来调用AudioFlinger提供的服务了。我们以图13-22来总结这一小节。

创建了AudioTrack后，应用实例就可以通过不断写入（AudioTrack::write）音频数据来回放声音。这部分代码与音频数据流有关，我们也放在后面小节中分析。

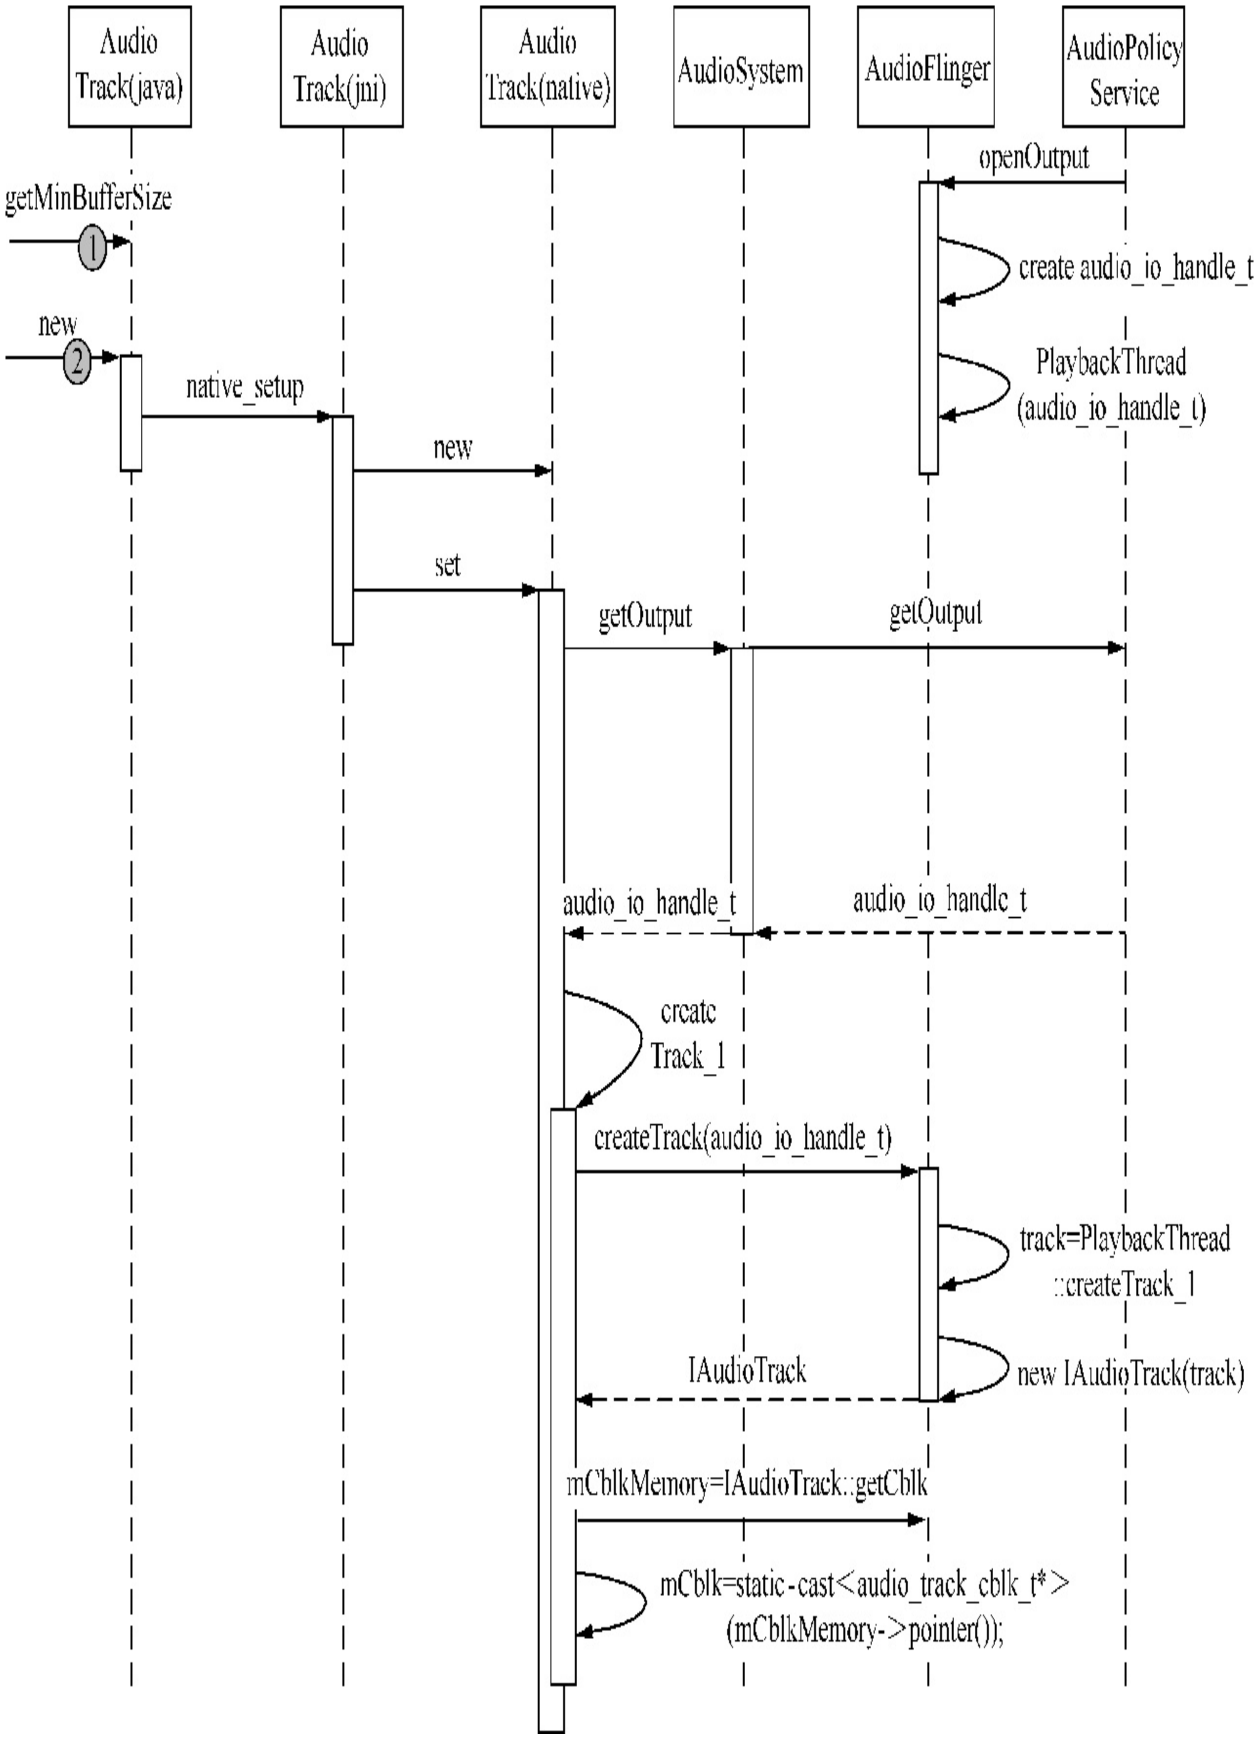

Audio Track(java)
Audio Track(jni)
Audio Track(native)
AudioSystem
AudioFlinger
AudioPolicy Service
openOutput
getMinBufferSize
1
create audio_io_handle_t
new
2
PlaybackThread (audio_io_handle_t)
native_setup
new
set
getOutput
getOutput
audio_io_handle_t
audio_io_handle_t
create Track_1
createTrack(audio_io_handle_t)
track=PlaybackThread ::createTrack_1
IAudioTrack
new IAudioTrack(track)
mCblkMemory=IAudioTrack::getCblk
mCblk=static-cast<audio_track_cblk_t*> (mCblkMemory->pointer());

▲图13-22　AudioTrack的创建流程图

13.5.2　AudioPolicyService的路由实现

我们在AudioPolicyService小节曾将其比作一个“路由器”，不过还没有深入解析它是如何完成路由路径的选择的。这个功能的实现与使用者——AudioTrack有很大关联，所以我们特地放在本小节进行剖析，希望读者可以综合起来理解。

“路由器”（AudioPolicyService）由如下几个核心部分组成。

- 与发送方（AudioTrack）的接口

“路由器”首先要接收到一个IP数据包才能去做路由处理，否则就会变成“无源之水”。

- 与接收方（AudioFlinger）的接口

道理和上面类似，AudioPolicyService内部拥有当前系统中所有音频设备的信息。这就好比一个“路由器”也需要预先知道它有多少个路由节点，才可能把音频数据发送到下一个正确的节点。

- 路由路径的算法策略

“路径选择策略”是AudioPolicyService的重点。和传统的“路由器”不同，它的路径选择算法并不是固定的，而是通过灵活的定制方式由各厂商自行实现。

大家应该还记得在前面AudioTrack范例小节的分析中，我们调用了AudioSystem::getOutput。即：

```
status_t AudioTrack::set(…)
{…
    audio_io_handle_t output = AudioSystem::getOutput(streamType,
                                                       channel Mas
…}
```

AudioSystem只是一个中介，其中的实现还是由

AudioPolicyService完成的：

```
audio_io_handle_t AudioSystem::getOutput(…)
{
    const sp<IAudioPolicyService>& aps = AudioSystem::get_audio_p
    if (aps == 0) return 0;
    return aps->getOutput(stream, samplingRate, format, channels,
}
```

显然是直接调用了AudioPolicyService的服务接口：

```
audio_io_handle_t AudioPolicyService::getOutput(...)
{   …
    Mutex::Autolock _l(mLock);
    return mpAudioPolicy->get_output(mpAudioPolicy, stream, sampl
    channelMask, flags);
}
```

变量mpAudioPolicy便是由策略制定者“生产”出来的Policy。在原生态的实现中它代表的是legacy_audio_policy::policy@Audio_policy_hal.cpp，因而上面的get_output实际上调用的是如下函数：

```
static audio_io_handle_t ap_get_output(struct audio_policy *pol,…
{
    struct legacy_audio_policy *lap = to_lap(pol);
    return lap->apm->getOutput((AudioSystem::stream_type)stream,
                               format,channelMask,(AudioSystem::ou
}
```

也就是说，前面的getOutput的接口实现最终是落在getOutput@AudioPolicyManagerBase（Audio PolicyManagerDefault继承自AudioPolicyManagerBase，而后者又继承自AudioPolicyInterface）中。

我们先来看看AudioPolicyManagerBase的getOutput实现：

```
/*hardware/libhardware_legacy/audio/AudioPolicyManagerBase.cpp*/
audio_io_handle_t AudioPolicyManagerBase::getOutput(AudioSystem::
                             uint32_t samplingRate, uint32_t form
                             uint32_t channelMask, AudioSystem::o
{
    audio_io_handle_t output = 0;
    uint32_t latency = 0;
```

```
    /*Step 1. 获取stream音频类型对应的Strategy：*/
    routing_strategy strategy = getStrategy((AudioSystem::stream_
    audio_devices_t device = getDeviceForStrategy(strategy, false
    …
    /*Step 2. 应用策略，判断哪些Output符合用户传入的stream类型：*/
    SortedVector<audio_io_handle_t> outputs = getOutputsForDevice
    /*Step 3. 选择一个最适合的Output：*/
    output = selectOutput(outputs, flags);
    return output;
}
```

我们将上述代码段分为3个步骤。

Step1@AudioPolicyManagerBase::getOutput。每种Stream类型都有对应的路由策略（Routing Strategy），如AudioSystem::TTS 和AudioSystem::MUSIC两种“音频流”都对应的是STRATEGY_MEDIA；而AudioSystem::NOTIFICATION流则对应的是STRATEGY_SONIFICATION_RESPEC TFUL。

StreamType和RoutingStrategy的对应关系如表13-5所示。

表13-5　Stream类型与Strategy对照表

STREAM_TYPE	STRATEGY
VOICE_CALL	STRATEGY_PHONE
BLUETOOTH_SCO	
RING	STRATEGY_SONIFICATION
ALARM	
NOTIFICATION	STRATEGY_SONIFICATION_RESPECTFUL

DTMF	STRATEGY_DTMF
SYSTEM	STRATEGY_MEDIA
TTS	
MUSIC	
Default（默认情况下）	
ENFORCED_AUDIBLE	STRATEGY_ENFORCED_AUDIBLE

由此可见，不同的Stream类型也有可能被划归到同一个Strategy。比如TTS、MUSIC及SYSTEM类型的音频，它们在路由策略上都遵循STRATEGY_MEDIA。另外，默认情况下系统会采用STRATEGY_MEDIA类型的策略。当然，我们也可以通过重载getStrategy来按自己的要求划分Strategy。

当找到某Stream类型对应的Strategy后，接下来的getDeviceForStrategy将进一步为这一Strategy匹配最佳的音频设备（以STRATEGY_MEDIA为例）：

```
audio_devices_t AudioPolicyManagerBase::getDeviceForStrategy(rout
{
   uint32_t device = AUDIO_DEVICE_NONE;
    …
    switch (strategy) {…
    case STRATEGY_MEDIA: {
         uint32_t device2 = AUDIO_DEVICE_NONE;
         …
         if ((device2 == AUDIO_DEVICE_NONE) &&mHasA2dp &&
              (mForceUse[AudioSystem::FOR_MEDIA] != AudioSystem::
```

```
            (getA2dpOutput() != 0) && !mA2dpSuspended) {
        device2 = mAvailableOutputDevices & AUDIO_DEVICE_OUT_BLU
        if (device2 == AUDIO_DEVICE_NONE) {
            device2 = mAvailableOutputDevices &
                              AUDIO_DEVICE_OUT_BLUETOOTH_A2DP_HE
        }
        if (device2 == AUDIO_DEVICE_NONE) {
            device2 = mAvailableOutputDevices &
                              AUDIO_DEVICE_OUT_BLUETOOTH_A2DP_SP
        }
    }
    if (device2 == AUDIO_DEVICE_NONE) {
        device2 = mAvailableOutputDevices & AUDIO_DEVICE_OUT_WI
    }
    if (device2 == AUDIO_DEVICE_NONE) {
        device2 = mAvailableOutputDevices & AUDIO_DEVICE_OUT_WI
    }
    if (device2 == AUDIO_DEVICE_NONE) {
        device2 = mAvailableOutputDevices & AUDIO_DEVICE_OUT_US
    }
    if (device2 == AUDIO_DEVICE_NONE) {
        device2 = mAvailableOutputDevices & AUDIO_DEVICE_OUT_US
    }
    …//其他优先级匹配做法类似，代码略
    device |= device2;
    if (device) break;//经过上面步骤后，找到合适的device，可以直接跳出
    device = mDefaultOutputDevice;//否则使用默认的device
    if (device == AUDIO_DEVICE_NONE) {//仍然没有匹配的device，这种
        ALOGE("getDeviceForStrategy() no device found for STRAT
    }
    } break;
…
```

上述代码段看上去很长，但逻辑其实很简单，即按照一定的优先级来匹配系统中已经存在的所有音频设备。这个优先级的设定因Strategy不同而有所差异。对于STRATEGY_MEDIA这种类型，其优先级如下所示（要注意，只有在上一步匹配失败后——即找不到合适的设备，变量device2为AUDIO_DEVICE_NONE的情况下，程序才会继续执行下一优先级的判断）：

- 如果平台有蓝牙A2dp，并且蓝牙A2dp通道可以正常打开，没有挂起，当前也没有强制不使用A2dp，那么通过匹配mAvailableOutputDevices来寻找合适的A2dp设备，如A2dp_headphone，A2dp_Speaker。

- 处于第二优先等级的是wired headphone。
- 继续寻找是否有wired headset。
- 寻找是否有usb accessory。
- 寻找是否有usb device。

……

按照上述的优先级匹配策略，正常情况下getDeviceForStrategy都能获得符合要求的device。我们再回到前面的getOutput，看看Step2的执行。

Step2@AudioPolicyManagerBase::getOutput。为Device选择合适的Output通道：

```
SortedVector<audio_io_handle_t> AudioPolicyManagerBase::getOutput
devices_t device,DefaultKeyedVector<audio_io_handle_t, AudioOutpu
{
    SortedVector<audio_io_handle_t> outputs;
    for (size_t i = 0; i < openOutputs.size(); i++) {…
        if ((device & openOutputs.valueAt(i)->supportedDevices())
            ALOGVV("getOutputsForDevice() found output %d", openO
            outputs.add(openOutputs.keyAt(i));
        }
    }
    return outputs;
}
```

这个函数用于获得所有支持device设备的output，并添加到outputs中。Output是前几个小节中分析的AudioFlinger::openOutput的执行结果，AudioPolicyService会把它们存储到mOutputs键值对中。因为每个output通常都支持若干种音频设备，且不同的output支持的音频设备类型不限，所以系统中很可能存在多个支持同一device的output。

Step 3@AudioPolicyManagerBase::getOutput。到目前为止，符合要求的Output可能不止一个，所以要选择一个最合适的（分段阅读）：

```
audio_io_handle_t AudioPolicyManagerBase::selectOutput(const Sort
```

```
{
   /*Step 1. 处理一些特殊情况:*/
    if (outputs.size() == 0) {
          return 0;
    }
    if (outputs.size() == 1) {
          return outputs[0];
    }
```

先处理一些特殊情况，如没有任何output存在的情况下只能返回空值；同样的，如果只有一个output的情况也没得选择，直接返回该output:

```
    /*Step 2. 开始择优判断*/
    int maxCommonFlags = 0;
    audio_io_handle_t outputFlags = 0;
    audio_io_handle_t outputPrimary = 0;

    for (size_t i = 0; i < outputs.size(); i++) {//逐个处理所有Outp
        AudioOutputDescriptor *outputDesc = mOutputs.valueFor(out
        //每个Output都有对应的描述符
        if (!outputDesc->isDuplicated()) {
           int commonFlags = (int)AudioSystem::popCount(outputDes
            if (commonFlags > maxCommonFlags) {//此Output的flags与
               outputFlags = outputs[i];
               maxCommonFlags = commonFlags;
               ALOGV("selectOutput() commonFlags for output %d, %
            }
            if (outputDesc->mProfile->mFlags & AUDIO_OUTPUT_FLAG_
                outputPrimary = outputs[i];
            }
        }
    }
```

上述代码段中的for循环是整个函数的核心，我们来分析下它的“决策准绳”。读者只要仔细看下for循环中的判断语句，就可以发现它实际上是在计算一个最大值maxCommonFlags。所以问题就转化为：maxCommonFlags是什么？

```
int commonFlags = (int)AudioSystem::popCount(outputDesc->mProfile
```

上面这句代码用通俗的话来讲，就是计算outputDesc->mProfile->mFlags与入参flags的“相似度”有多大。Flags有如下几种可供选择：

```
AUDIO_OUTPUT_FLAG_NONE = 0x0,
AUDIO_OUTPUT_FLAG_DIRECT = 0x1, //Output直接把track导向一个output st
AUDIO_OUTPUT_FLAG_PRIMARY = 0x2,//Primary Output，系统中只存在唯一的P
AUDIO_OUTPUT_FLAG_FAST = 0x4,    //支持fast tracks的output
AUDIO_OUTPUT_FLAG_DEEP_BUFFER = 0x8，//使用deep audio buffer的outpu
```

音频系统中名为output_flags的数据类型非常多，不过仔细回溯，还是不难发现这个flags是在AudioTrack的set函数中指定的。另外，如果在查找过程中发现了一个primary output，程序会用outputPrimary变量来表示，这在后面会用到：

```
/*Step 3. 根据优先级做出最后的选择*/
 if (outputFlags != 0) {
            return outputFlags;
     }
     if (outputPrimary != 0) {
            return outputPrimary;
     }
     return outputs[0];
}//AudioPolicyManagerBase::selectOutput结束
```

函数末尾会根据优先级做最终的“抉择”。优先级的排列很简单，即：

- Flags与要求相似度最高的Output；
- Primary Output；
- 如果上面两种都找不到，则默认返回第一个Output。

这样AudioPolicyService就完成了整个路由路径的选择，AudioTrack则是通过AudioSystem:: getOutput间接调用到AudioPolicyService提供的功能。

13.6 音频数据流

通过前面几个小节的学习，读者已经系统掌握了AudioTrack，AudioFlinger和AudioPolicy Service的内部实现。只不过还有一点欠缺，即我们始终没有详细分析在这几个跨进程的对象间，音频数据是如何传递的——因为如果一开始就讲解这其中的细节，很可能会让读者感觉很吃力，从而事倍功半。所以我们选择在读者理解了各个模块的运作方式后，再来对整个数据流的传递过程做统一分析。

首先来思考下在音频数据的传递过程中，会有哪些地方可能涉及内存申请——这对于嵌入式系统来说非常关键，因而是我们设计的重心。“可疑”的地方至少有：MediaPlayerService、AudioTrack、AudioFlinger、AudioPolicyService、AudioMixer以及HAL层的相关类。其中MediaPlayerService不在这个小节的讨论范围内，所以直接略过；而AudioPolicyService直接参与数据传递的可能性不大，也基本可以排除；剩下的就是如图13-23所示的几个对象。

点。

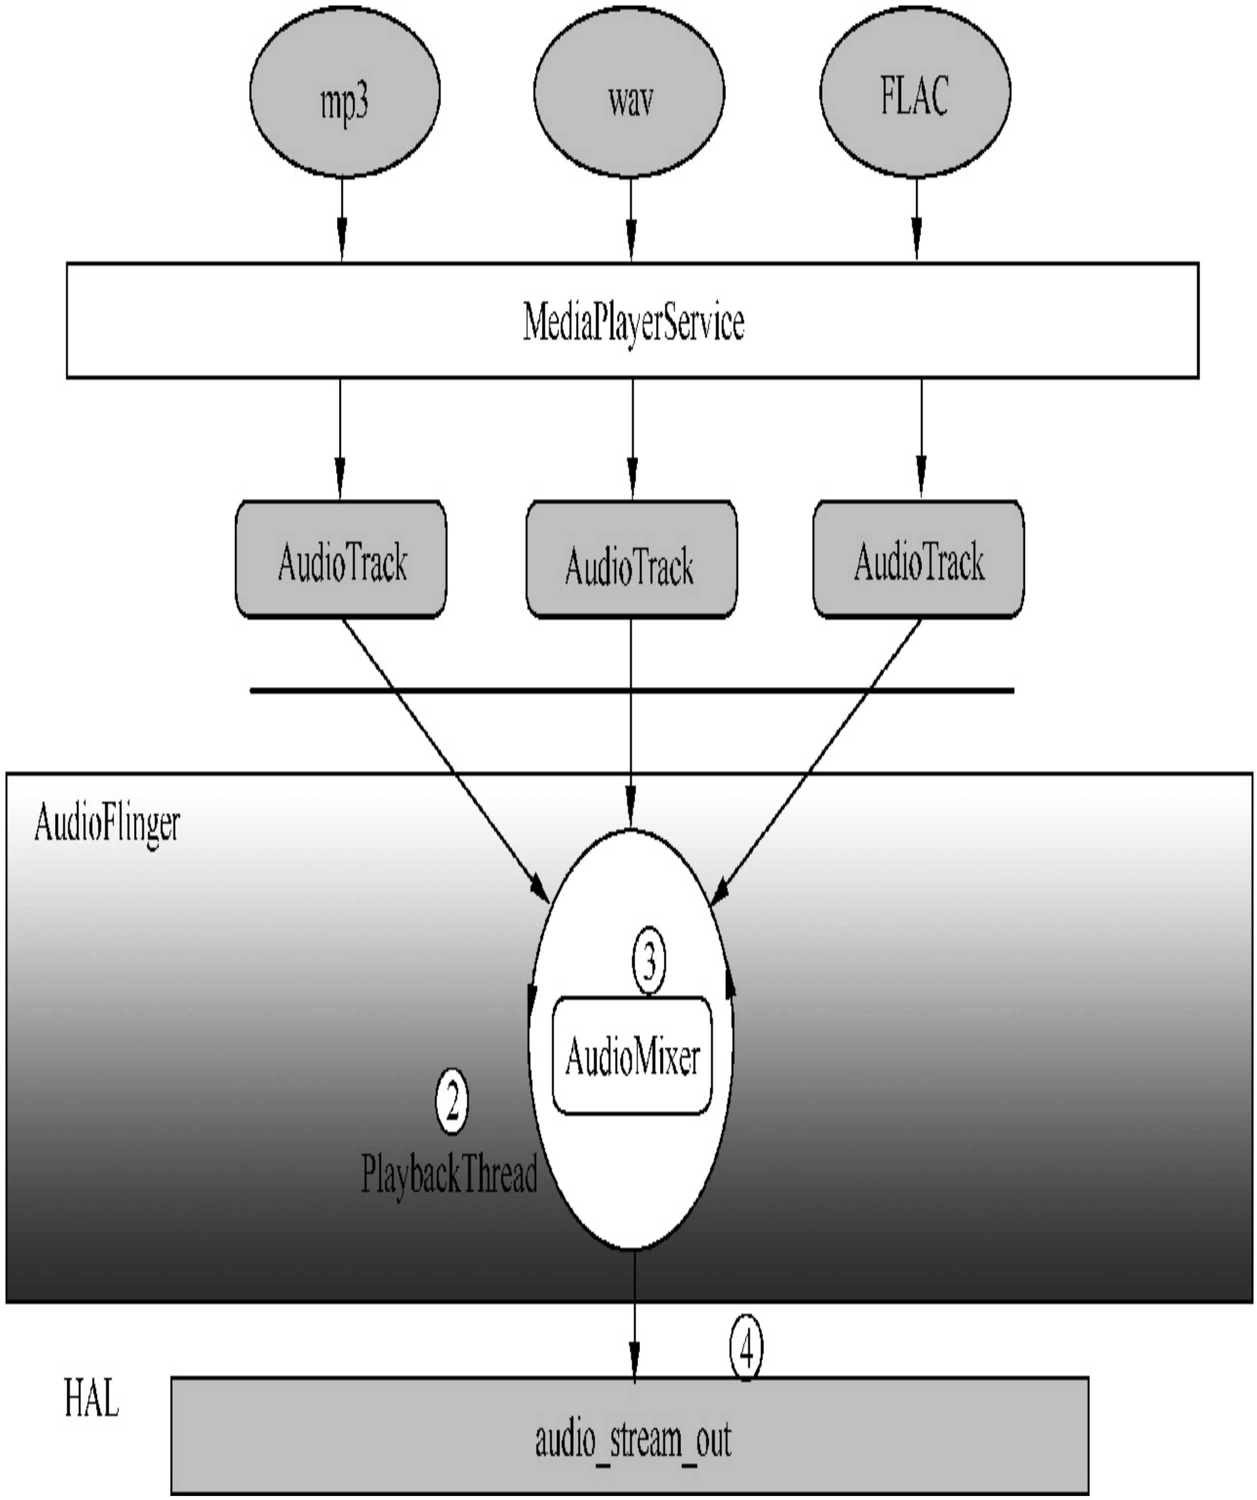

▲图13-23　Audio Playback数据流简图

按照音频的正常回放过程，该数据流简图主要包括如下几个核心点。

- 在这个简图中，假设我们需要同时播放3个音频文件（它们可以是mp3，wav或者系统支持的其他任何音频格式）
- 上层应用程序通过SDK提供的MediaPlayer来播放这几个音频文件，默认情况下它们的“音频流”类型都是STREAM_MUSIC。因为文件是保存在存储设备中的（比如flash、sd卡、U盘等），所以MediaPlayer面临的第一个问题是如何把音频文件读取到内存中——这涉及了文件系统的读写原理，因为不是本章关注的重点，所以不予深究。
- 当音频文件读取出来后，是不是直接可以播放了？显然不是，因为大多数音频文件在保存时都是先经过压缩处理的，所以此时就需要有对应的解码操作（可以采用“软件解码”，也可以采用“硬件解码”）。
- 音频数据解码后的处理才是我们想要了解的。MediaPlayer在MediaPlayerService的帮助下将完成包括解码在内的复杂操作；而MediaPlayerService实际上又是AudioTrack的使用者，即它的回放功能是由AudioTrack间接完成的。
- 一个AudioTrack只代表一个播放实例，而这个场景中却要求同时播放3个音频文件。这在智能操作系统里很常见，如播放音乐时接到短信提醒；或者同时打开3个MediaPlayer（系统支持同时运行多个MediaPlayer播放器）等，都需要系统能做出正确处理。既然我们可以同时运行多个AudioTrack实例，同时系统中也会有多个音频回放设备，那么AudioTrack和这些设备有什么对应关系呢？这就是AudioPolicyService所起到的作用。它根据每个AudioTrack所属的“流类型”来为它选择与当前系统最匹配的输出设备，然后查找支持此输出设备的AudioFlinger中的Output（即openOutput所打开的通道）。这有点类似于路由器的功能：在设定了源IP（AudioTrack）和目标IP（音频回放设备）后，寻找最佳的路由路径，因而AudioPolicyService的这一特性被称为“Routing Strategy”。这些知识点在AudioPolicyService小节已经详细介绍过，读者若不清楚可以回头复习下。
- AudioFlinger则是路由器的“底层通道”，它坚决执行AudioPolicyService的决策，正确地将各路音频数据进行混音，然后传递到HAL层，进而输出到最终的音频设备中。这个过程有点类似

于显示系统中的SurfaceFlinger。

- 在AudioFlinger中起到关键作用（音频回放）的有两个：一个是PlaybackThread，另一个是AudioMixer，后者是混音的核心。读者可以先来思考一下：它们两者是否共享同一块音频数据缓冲区呢?

通过上面的描述，我们可以归纳出音频流的几个关键“路由节点”，即AudioTrack，AudioFlinger中的PlaybackThread，AudioMixer和HAL层的实现（这些节点在图中都用数字序号分别标注）。

13.6.1 AudioTrack中的音频流

AudioTrack中对音频数据流的处理相对简单，我们仍然以前面小节的“AudioTrack应用范例”进行分析。AudioTrack为音频数据分配缓冲区空间对应的代码如下：

```
AudioTrack track = new AudioTrack(TEST_STREAM_TYPE, TEST_SR, TEST_
                                          TEST_FORMAT, 2 * minBuf
byte data[] = new byte[minBuffSize];
track.write(data, OFFSET_DEFAULT, data.length);
track.write(data, OFFSET_DEFAULT, data.length);
track.play();
```

这个范例中的音频数据（即data数组）是静态的，而不是从某个音频文件中解析出来的。而随后的write函数则负责将data数据写入AudioTrack中，这说明AudioTrack内部也一定申请了内存空间来存储音频数据。具体流程如下：

（1）AudioTrack(java)构造时，传入bufferSizeInBytes：

```
public AudioTrack(int streamType, int sampleRateInHz, int channel
           int bufferSizeInBytes, int mode, int sessionId)
```

在上面的范例中，bufferSizeInBytes 对应的是2 * minBuffSize。

（2）AudioTrack(java)的构造函数调用native_setup，将上述bufferSizeInBytes值传入JNI层，即android_media_AudioTrack_native_setup@android_media_AudioTrack.
接着AudioTrack(cpp)对象会被创建，且它的构造函数不带任何参数：

```
sp<AudioTrack> lpTrack = new AudioTrack();
```

在静态模式（MODE_STATIC）下，我们通过set函数将数据地址传给AudioTrack(cpp)：

```
lpTrack->set(…lpJniStorage->mMemBase,…);
```

变量lpJniStorage是AudioTrackJniStorage类型的对象，它会事先分配一定的内存空间。具体代码如下：

```
lpJniStorage->allocSharedMem(buffSizeInBytes)
```

流模式下（MODE_STREAM）的音频数据是分多次传递的，这种情况下AudioTrack不需要主动使用AudioTrackJniStorage来申请内存空间，而是后期由AudioFlinger根据需求分配一块缓冲区。缓冲区头部为audio_track_cblk_t，以mCblk表示，这个变量在AudioTrack::createTrack_l中初始化。源代码如下：

```
sp<IAudioTrack> track = audioFlinger->createTrack(…frameCount,…);
…
sp<IMemory> iMem = track->getCblk();//向AudioFlinger申请数据缓冲空间
…
mAudioTrack = track;//与AudioFlinger的通信中介
mCblkMemory = iMem;
audio_track_cblk_t* cblk = static_cast<audio_track_cblk_t*>(iMem-
mCblk = cblk;
```

上述frameCount参数是经过buffSizeInBytes，channel数量及bytesPerSample计算出来的，前几个小节已经讲解过。通过createTrack，我们建立起本地AudioTrack与远程AudioFlinger间的联系（IaudioTrack），然后利用IAudioTrack来向AudioFlinger请求申请内存空间（getCblk）。可想而知，这块空间必然是要能跨进程共享的（因为它是后续“生产者和消费者”共同操作的区域）。我们来看看它的Server端实现：

```
/*frameworks/av/services/audioflinger/Tracks.cpp*/
sp<IMemory> AudioFlinger::TrackHandle::getCblk() const {
    return mTrack->getCblk();
}
```

IAudioTrack在AudioFlinger中的实现是TrackHandle。而mTrack是一个PlaybackThread::Track，它是在AudioFlinger::createTrack时生

成的。具体代码如下：

```
PlaybackThread *thread = checkPlaybackThread_l(output);
…
//下面这个track就是上面的mTrack
track = thread->createTrack_l(client, streamType, sampleRate, for
channelMask, frameCount, sharedBuffer, lSessionId, flags, tid, &l
```

所以mTrack是隶属于某个特定PlaybackThread实例的（每个AudioTrack在AudioFlinger中都有一个对应的PlaybackThread，这与它的“流类型”以及当前设备的AudioPolicyService策略有关）。我们来看看PlaybackThread::Track中如何生成一块内存区域，如图13-24所示。

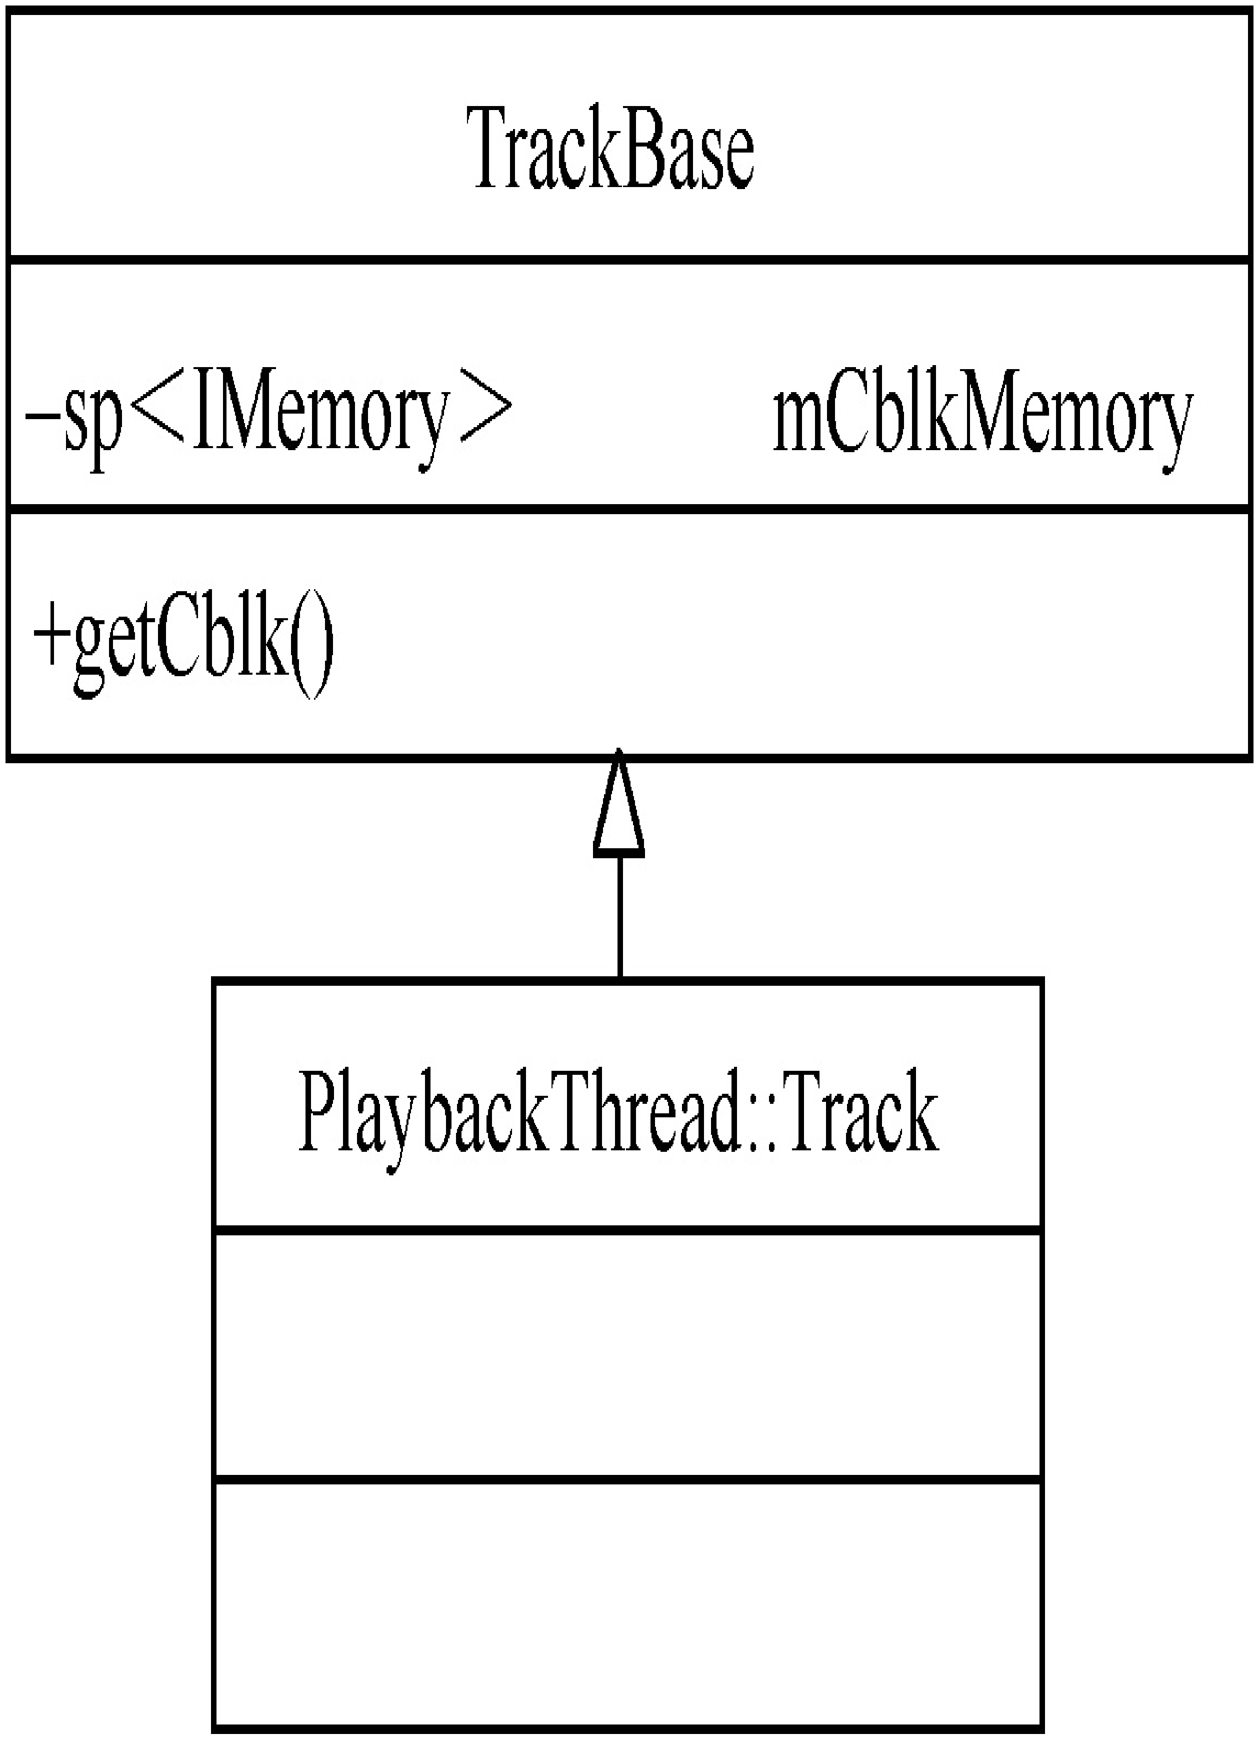
TrackBase
−sp<IMemory> mCblkMemory
+getCblk()
PlaybackThread::Track

▲图13-24 Track中的数据块

Track继承自TrackBase，后者的构造函数中将申请所需的内存单元。代码如下：

```
AudioFlinger::ThreadBase::TrackBase::TrackBase(…const sp<Client>&
{…
      size_t size = sizeof(audio_track_cblk_t);
      size_t bufferSize = frameCount* mFrameSize;
      if (sharedBuffer == 0) {
          size += bufferSize;
      }
      if (client != NULL) {
          mCblkMemory = client->heap()->allocate(size);
      …
}
```

首先计算缓冲区的大小，frameCount是哪里得到的呢？它是由AudioTrack在native_setup时计算出来，并传递给AudioFlinger的。公式如下：

```
int bytesPerSample = audioFormat == javaAudioTrackFields.PCM16 ?
int frameCount = buffSizeInBytes / (nbChannels * bytesPerSample);
```

也就是：

```
bufferSize=frameCount*channelCount*sizeof(int16_t)
=(buffSizeInBytes / (nbChannels * bytesPerSample))* channelCount*
=buffSizeInBytes
```

变量buffSizeInBytes是在创建AudioTrack(java)对象时提供的。如果是STATIC模式，要求这个值是回放的音频数据大小的最大值；如果是STREAM模式，可以小于声音数据的实际大小，不过通常需要比getMinBufferSize大，否则会初始化失败。在前面AudioTrack的范例中，buffSizeInBytes是getMinBufferSize*2。

需要申请的内存大小为size，它是audio_track_cblk_t头部大小再加上bufferSize（MODE_STREAM时）得到的，为什么需要一个audio_track_cblk_t呢？

举个例子，TCP/IP中的通信双方在发送实际的数据内容前需要加上

一个数据头，用以描述数据块的各种属性。也就是：

```
<data> = <head>+<body>
```

与此类似，audio_track_cblk_t是<head>，而bufferSize则是<body>的大小。在TrackBase中，mCblkMemory指向的是整块数据区，mCblk则指向的是数据区的audio_track_cblk_t头。当然从指针的角度来看，二者的值是一致的——这点希望读者在分析代码时特别注意。数据区的空间申请主要采用的是：

```
mCblkMemory = client->heap()->allocate(size);
```

上面这句代码表明变量mCblkMemory指向的内存地址由client来指定，那么这个client又是怎么来的呢？它是在AudioFlinger::createTrack中生成的，并由AudioFlinger::mClients来维护。换句话说，虽然每个PlaybackThread有使用内存空间的权利，但是真正的内存申请与回收则仍是由AudioFlinger来全盘掌控的：

```
sp<IAudioTrack> AudioFlinger::createTrack(…)
{ …
      sp<Client> client;
      …
      client = registerPid_l(pid);
```

函数registerPid_l除了为当前的pid（这个pid值是AudioTrack调用AudioFlinger::createTrack时传入的，代表了AudioTrack所在进程的ID）生成一个AudioFlinger::Client实例外，还将<pid_t, wp<Client>键值对添加到mClients中。这也从一个侧面说明，每一个AudioTrack在AudioFlinger中有且仅有一个Client实体。那么，Client又是如何管理内存的呢？

先来看看它的构造函数：

```
AudioFlinger::Client::Client(const sp<AudioFlinger>& audioFlinger
    :   RefBase(),mAudioFlinger(audioFlinger),
        mMemoryDealer(new MemoryDealer(1024*1024, "AudioFlinger::
        mPid(pid), mTimedTrackCount(0)
{
    // 1 MB of address space is good for 32 tracks, 8 buffers eac
}
```

从上述源码段的注释可以略知一二：Client默认情况下申请了1024*1024=1MB大小的内存空间——这对于32路Track，每路8个buffer，每个buffer占4KB的情况已经足够（32*8*4KB=1MB）。

由于每路Track所需的空间大小不同，所以它们建立时需要由mCblkMemory向Client进行“实报实销”，如：

```
mCblkMemory = client->heap()->allocate(size);
```

实际上Client也不是最终的内存管理者，其内部还集成了MemoryDealer。MemoryDealer内部分为两部分，即：

- 堆（heap）内存块MemoryHeapBase;
- 分配和回收策略mAllocator。

我们在后面分析数据的跨进程传递时再做详细讲解。

到目前为止，AudioTrack和AudioFlinger中与音频数据相关的内存空间已经比较明了，我们来做个小结（在MODE_STREAM的情况下）。

- AudioTrack(java)在构造时，通过本地方法native_setup来传递上层应用计算出所需的最小音频数据空间。

- native_setup负责生成AudioTrack(cpp)对象，此时还不涉及内存申请。随后它调用AudioTrack::set接口，并将上层应用计算出的数据空间大小转化为frameCount。

- 在set实现中，首先要找到匹配的AudioFlinger中的PlaybackThread，接着调用AudioFlinger:: createTrack在PlaybackThread中新增一个Track，同时建立AudioTrack与AudioFlinger间的通信接口IAudioTrack。此时在AudioFlinger内部的Track生成过程中，会由TrackBase来申请相应的内存空间——不过AudioTrack显然还不知道这一数据空间的存在。

- 接下来AudioTrack可以通过IAudioTrack::getCblk来获得这个数据空间。

- 之后双方就能够利用这个数据缓冲区空间来传递音频数据了：

在AudioTrack中，它是由AudioTrack::mCblkMemory来指示的；在AudioFlinger中，它是由TrackBase::mCblkMemory来指示的。

下一小节我们详细讲解两个跨进程的对象（AudioTrack和AudioFlinger）间是如何共享音频数据空间的。

13.6.2 AudioTrack和AudioFlinger间的数据交互

AudioTrack与AudioFlinger是如何完成跨进程的数据传递的呢？

回答这个问题，可以从AudioTrack.write入手。

为了简化分析过程，我们直接来看native层的AudioTrack.write，而Java层的实现相对简单，不再一一讲解：

```
/*frameworks/av/media/libmedia/AudioTrack.cpp*/
ssize_t AudioTrack::write(const void* buffer, size_t userSize)
{
    if (mSharedBuffer != 0 || mIsTimed) {
        return INVALID_OPERATION;
    }//STATIC模式下，数据是一次就写完的,不需要调用write
    …
    //Step 1.准备与数据空间有关的参数
    mLock.lock();
    sp<IAudioTrack> audioTrack =mAudioTrack;//mAudioTrack是前面Aud
    sp<IMemory> iMem = mCblkMemory;//mCblkMemory是前面IAudioTrack:
    mLock.unlock();

    //Step 2.写入数据
    ssize_t written = 0;
    const int8_t *src = (const int8_t *)buffer;
    Buffer audioBuffer;
    size_t frameSz = frameSize();
    do {
        audioBuffer.frameCount = userSize/frameSz;
        status_t err = obtainBuffer(&audioBuffer, -1);
        …
        size_t toWrite;
        if (mFormat == AUDIO_FORMAT_PCM_8_BIT &&!(mFlags & AUDIO_
            …
        } else {
            toWrite = audioBuffer.size;
            memcpy(audioBuffer.i8, src, toWrite); //内存复制
        }
```

```
        src += toWrite; //指针跳过已经写入的数据
        userSize -= toWrite; //剩余数据量
        written += toWrite; //已经写入的数据量
        releaseBuffer(&audioBuffer); //释放audioBuffer
    } while (userSize >= frameSz); //循环写入数据
    return written;
}
```

函数write分为两个步骤。

Step1@AudioTrack::write。得到AudioTrack与AudioFlinger间的IPC通道IAudioTrack，以及数据缓冲区头指针mCblkMemory，后者是通过前者的getCblk接口获取的。而如果读者仔细观察，会发现这个函数中并没有直接用到这两个变量，那么为什么要获取它们呢？原因在于利用强指针的特性来保证它们不会被释放。

Step2@AudioTrack::write。读者可以思考一下：程序在处理数据复制时的正常流程是怎样的呢？如果以src、dst、cur分别代表源数据、目的数据区和当前要处理的数据起点，那么无非就是借助于cur，通过多次循环将src中的数据复制到dst缓冲区中。在write这个例子中的处理方法也类似，只不过目的区用audioBuffer进行了封装。

接下来我们详细分析AudioTrack和AudioFlinger是如何通过mCblkMemory这块内存区来实现“生产者-消费者”数据交互的。需要考虑的问题包括：

- AudioTrack是生产者，AudioFlinger是消费者，它们如何跨进程地共享一个缓冲区；
- mCblkMemory是不是环形数据区，如果是又是如何实现的；
- “生产者-消费者”模型在这个场景中的具体应用。

（1）先用一个简图来描绘下mCblkMemory的内部结构，如图13-25所示。

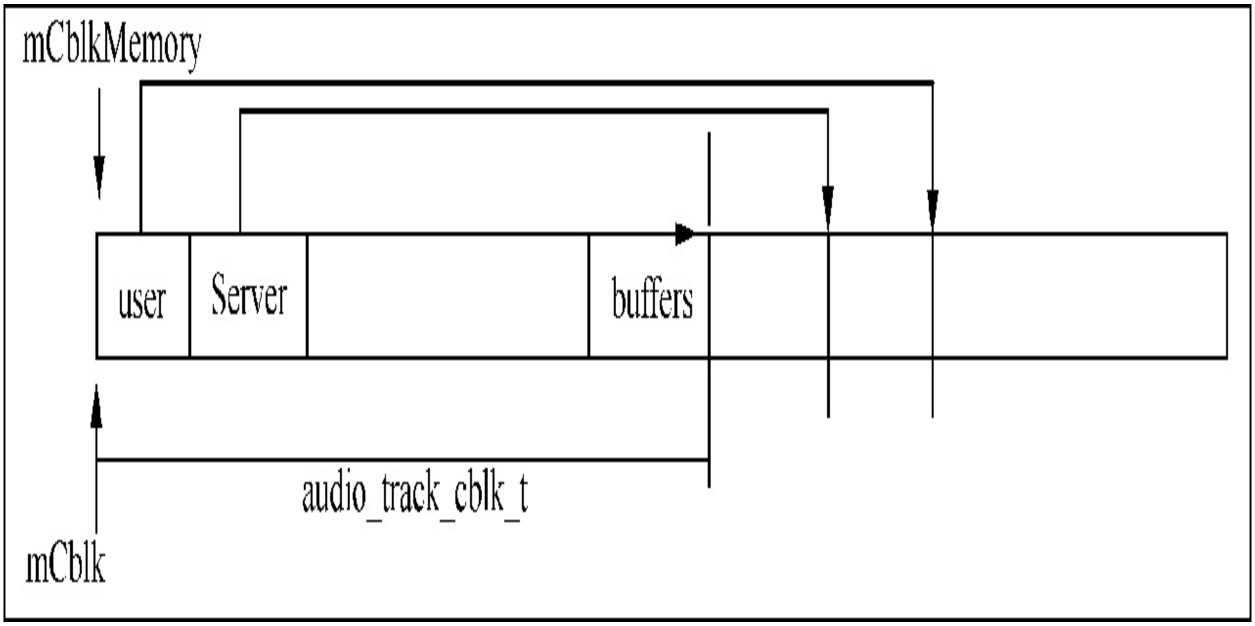

▲图13-25　IMemory内部结构图

内存块头部audio_track_cblk_t中有几个重要变量的释义，如表13-6所示。

表13-6　audio_track_cblk_t重要内部变量释义

变　　量	释　　义
uint32_t　　user;	生产者指针
uint32_t　　server;	消费者指针

要特别注意，user是生产者而server是消费者，这和我们最初的理解可能有点差异。

（2）生产者如何判断是否有可用的缓冲区来填充数据呢？这就是framesAvailable@ audio_track_cblk_t所要完成的工作：

```
/*frameworks/av/media/libmedia/AudioTrackShared.cpp*/
```

```
uint32_t audio_track_cblk_t::framesAvailable(size_t frameCount, b
{
    Mutex::Autolock _l(lock);
    return framesAvailable_l(frameCount, isOut);
}
uint32_t audio_track_cblk_t::framesAvailable_l(size_t frameCount,
{
    uint32_t u = user;
    uint32_t s = server;

    if (isOut) {
        uint32_t limit = (s < loopStart) ? s : loopStart;
        return limit + frameCount - u;
    } else {
        return frameCount + u - s;
    }
}
```

上面代码段中的变量isOut用于表示当前是回放音频还是录制音频。

也就是说，如果在isOut为true(Playback)的情况下，framesAvailable_l的标准就是limit+frameCount-u。通常limit就是s自身，因而是s+frameCount-u。用通俗的话来解释就是：

剩余可用空间（framesAvailable）=“总共有多少空间”（frameCount）-“用掉了多少”（u）+“回收了多少”（s）。

消费者这边判断当前是否有可读数据，则由framesReady来完成。其实现和framesAvailable类似，读者可以自行分析。

（3）在前面的AudioTrack::write中，我们通过obtainBuffer获取了目标区的写入地址，下面来看看它是如何实现的：

```
status_t AudioTrack::obtainBuffer(Buffer* audioBuffer, int32_t wa
{…
    uint32_t framesReq = audioBuffer->frameCount;//Step 1.用户申请
    …
    uint32_t framesAvail = mProxy ->framesAvailable(); //Step 2.当
    …//当可用空间大小为0时的一些处理
    if (framesReq > framesAvail) {
        framesReq = framesAvail; //Step 3.请求的大小超过可用大小
    }
    uint32_t u = cblk->user;
```

```
    uint32_t bufferEnd = cblk->userBase + mFrameCount;
    if (framesReq > bufferEnd - u) {
        framesReq = bufferEnd - u; //Step 4.确定用户可以申请到的空间大
    }
    …
    audioBuffer->raw = mProxy ->buffer(u); //Step 5.确定可供用户使用
    active = mActive;
    return active ? status_t(NO_ERROR) : status_t(STOPPED);
}
```

Step1@AudioTrack::obtainBuffer。变量framesReq的初始值是audioBuffer->frameCount，即用户请求的空间大小。用户申请的这个大小并不一定能得到满足，后面会根据实际情况对其进行适当修正。

Step2@AudioTrack::obtainBuffer。函数framesAvailable用于计算当前可供生产者使用的空间大小，前面已经讲解过，此处不再赘述。

Step3@AudioTrack::obtainBuffer。如果当前剩余的可用空间已经小于用户的请求大小，那么只能满足用户的一部分需求。

Step4@AudioTrack::obtainBuffer。判断剩余空间是否涉及环形的情况，我们会结合下一步来进行完整分析。

Step5@AudioTrack::obtainBuffer。得出可用空间的大小并不算完成所有工作，我们还必须计算目标区的起始地址，所以调用buffer()函数。这个函数实现相当简单，只有短短一句话，但起到了很关键的作用（Proxy直接又调用了audio_track_cblk_t中的实现）：

```
void* audio_track_cblk_t::buffer(void *buffers, size_t frameSize,
{
    return (int8_t *)buffers + (offset - userBase) * frameSize;
}
```

其中buffers指向的是数据区的起点，offset是user（生产者）指针。因为这些变量都以frame为单位，所以还要换算成字节单位，即乘以frameSize。

我们知道，user是生产者的当前指针，那么userBase又是什么呢？

如果不考虑环形缓冲区，事情确实会简单很多。但不幸的是，我们必须实现环形的数据读写方法。通过搜索源码，可以发现userBase在

audio_track_cblk_t::stepUser中会被不断赋值，所以我们一并分析这个函数。

当得到目标区的可用大小以及起始地址后，生产者就开始执行任务，并把数据写入缓冲区中。在这之后，它还有一件事要做，即通过stepUser来调整缓冲区的状态（在releaseBuffer中调用）。或者更确切地说，更新user（生产者）在缓冲区中的状态：

```
/*frameworks/av/media/libmedia/AudioTrackShared.cpp*/
uint32_t audio_track_cblk_t::stepUser(size_t stepCount, size_t fr
{…
    uint32_t u = user;
    u += stepCount;//跳过已经处理的数据
    if (isOut) {…
    } else if (u > server) {//在Record的情况下，user不应该超过server
        ALOGW("stepUser occurred after track reset");
        u = server;
    }

    if (u >= frameCount) {
        if (u - frameCount >= userBase ) {
            userBase += frameCount;
        }
    } else if (u >= userBase + frameCount) {
          userBase += frameCount;
    }

    user = u;
    …
    return u;
}
```

函数开头先把u(user)向前推进了stepCount，即刚刚写入缓冲区的数据大小，此时user有可能已经到达整个缓冲区的末尾。但如果server也已经读取了一部分数据，那么理论上来讲数据区的开头一部分又是可供生产者使用的区域，这就是环形缓冲区的一个特点。那么，如何判断出这种情况呢？

结合前面buffer()函数中的offset-userBase，读者可以想象一下——如果userBase的值已经是整个数据区大小，那么当offset达到末尾时，offset-userBase实际上也就是缓冲区的开头。所以上述函数首先根据if (u >= frameCount)，即user是否已经超过frameCount，来判断userBase是否需要更新。很显然，如果user又绕了环一圈（即u -

frameCount>= userBase），那么userBase就得再加上一圈的大小。这样后面再执行offset-userBase时，则user又像从头开始写数据了。如此循环反复，直到“生产者-消费者”之间的交互结束。

有了这个基础，我们再来理解上一步中的bufferEnd变量就容易多了，如图13-26所示。

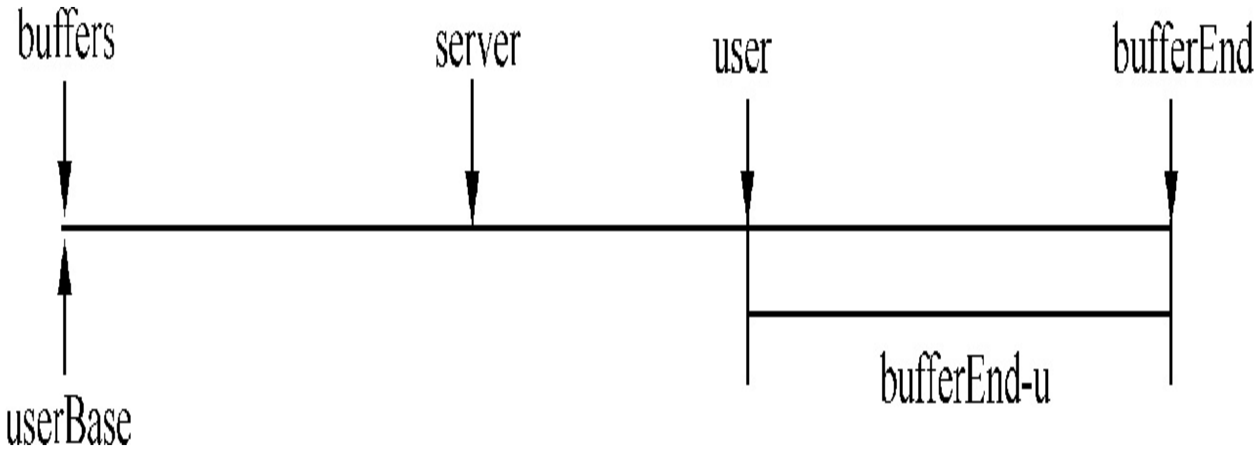

▲图13-26　bufferEnd的含义

假设此时userBase指向的是buffers位置（userBase每次都以frameCount为单位进行增加），虽然理论上可用的空间是frameCount-user+server，但是从userBase到server这一段却是无法使用的（因为我们只是模拟了一个环形数据区，但在进行memcpy内存复制时它还是只朝一个方向前进），所以实际可用内存空间就是bufferEnd-u了。

这个环形区使用得比较巧妙，读者可以再仔细体会下。

（4）现在我们应该已经明白AudioTrack和AudioFlinger是如何利用环形数据区进行读写操作了，接下来具体分析下它们是如何同步共享这块数据区的。

在前面的AudioTrack::write中，我们发现它分别使用了obtainBuffer和releaseBuffer来访问缓冲区，那是不是在这里面使用了同步机制呢？

AudioTrack::obtainBuffer这个函数前面已经分析过，这里我们从资源互斥的角度来重新审视一遍：

```
status_t AudioTrack::obtainBuffer(Buffer* audioBuffer, int32_t wa
{…
    AutoMutex lock(mLock);
    …
    audio_track_cblk_t* cblk = mCblk;
    …
    uint32_t framesAvail = mProxy->framesAvailable();
    if (framesAvail == 0) {
        … //下面有详细分析
    }
    …
    return active ? status_t(NO_ERROR) : status_t(STOPPED);
}
```

这个函数的开头使用了一个AutoMutex对象（实际上就是一个Autolock），来保证函数内操作的唯一性。

还记得我们在本书进程同步互斥章节所举的“生产者-消费者”的经典例子吗？

对于生产者来说，执行步骤是：

- 循环开始；
- Produce_item;
- P(S_emptyCount)；
- P(S_mutex)；
- Put_item_to_buffer；
- V(S_mutex)；
- V(S_fillCount)；
- 继续循环。

对于消费者来说，执行步骤是：

- 循环开始；
- P(S_fillCount)；
- P(S_mutex)；
- Read_item_from_buffer；
- V(S_mutex)；
- V(S_emptyCount)；
- Consume；
- 继续循环。

而对于AudioTrack这个生产者来说，它可以直接套用上面的实现吗？显然不行。因为经典生产者-消费者的例子中假设缓冲区的大小是分为几等份的，每次生产者或者消费者都只是生产或消耗其中的一份。而AudioTrack与AudioFlinger对共享缓冲区的写入和读取则是未知的，或者更确切地说不是每次都相等的。这也就是framesAvailable()和framesReady()存在的意义：

```
uint32_t audio_track_cblk_t::framesAvailable(size_t frameCount, b
{
    Mutex::Autolock _l(lock);
    return framesAvailable_l(frameCount, isOut);
}
```

这个函数中使用了audio_track_cblk_t::lock这个mutex，它保证了AudioTrack是当前唯一进入缓冲区的对象。这样framesAvailable_l才能正确计算出当前是否有可用空间（即缓冲区是否满的问题）。如果当前已经没有可用空间，即framesAvailable返回为0，应该怎么办呢?按照PV原语的实现，当然就是要唤醒消费者去读取数据。下面看看obtainBuffer中当framesAvail == 0时的处理：

```
//下面这段代码摘取自obtainBuffer：
     if (framesAvail == 0) {
        cblk->lock.lock(); //没有使用AutoLock，那么末尾要记得unlock()
```

```
        goto start_loop_here;
        while (framesAvail == 0) {
            …
            if (CC_UNLIKELY(result != NO_ERROR)) {
                cblk->waitTimeMs += waitTimeMs;
                if (cblk->waitTimeMs >= cblk->bufferTimeoutMs) {
                    if (cblk->user < cblk->loopEnd) {
                        …
                        cblk->lock.unlock();
                        result = mAudioTrack->start();
                        cblk->lock.lock();
                        …
                    }
                    cblk->waitTimeMs = 0;
                }
                if (--waitCount == 0) {
                    cblk->lock.unlock();
                    return TIMED_OUT;
                }
            }
        start_loop_here:
            framesAvail = mProxy->framesAvailable_l(); //再次验证是
        }//while循环结束
        cblk->lock.unlock(); //与开头的lock()相配套
    }
```

如果framesAvail为0，则一直在while循环体中，直到framesAvailable_l返回的值不为0，或者尝试次数超限时返回。

循环过程中有时需要通知AudioFlinger。对应代码如下：

```
cblk->lock.unlock();
result = mAudioTrack->start();
cblk->lock.lock();
```

在调用start前，必须先释放lock，否则AudioFlinger无法正常执行。接着再次获取这个lock，然后判断是否有可用空间——如果仍然没有就继续执行循环。

在AudioTrack正常写入数据后，它调用releaseBuffer来更新user指针（stepUser）。因为user不属于共享资源，也就不需要特别的锁保护。

AudioTrack就是这样通过Mutex来与AudioFlinger互斥共享缓冲

区，并实现音频数据流的正确传递的。AudioFlinger中的实现略有差异，但基本原理一样，请读者自行分析。

（5）我们再来看最后一个问题，即AudioTrack和AudioFlinger是如何跨进程共享缓冲区的。换句话说，它们如何保证双方操作的是同一块数据区？

要回答这个问题，可以从缓冲区的内存申请过程入手。我们知道，这两个进程间的缓冲区是由AudioFlinger在创建一个Track时申请的，而所有Track的内存分配又由mClient来管理。Client内部包含了一个MemoryDealer对象来处理内存申请（见图13-27），所以最后的实现就是由它来完成的：

```
/*frameworks/native/libs/binder/MemoryDealer.cpp*/
MemoryDealer::MemoryDealer(size_t size, const char* name)
    : mHeap(new MemoryHeapBase(size, 0, name)),
    mAllocator(new SimpleBestFitAllocator(size))
{
}
```

它有两个重要的成员变量，其中mHeap负责申请内存，mAllocator则负责管理内存：

```
MemoryHeapBase::MemoryHeapBase(size_t size, uint32_t flags, char
    : mFD(-1), mSize(0), mBase(MAP_FAILED), mFlags(flags),
      mDevice(0), mNeedUnmap(false), mOffset(0)
{
    const size_t pagesize = getpagesize();
    size = ((size + pagesize-1) & ~(pagesize-1));
    int fd = ashmem_create_region(name == NULL ? "MemoryHeapBase"
    ALOGE_IF(fd<0, "error creating ashmem region: %s", strerror(e
    if (fd >= 0) {
        if (mapfd(fd, size) == NO_ERROR) {
            if (flags & READ_ONLY) {
                ashmem_set_prot_region(fd, PROT_READ);
            }
        }
    }
}
```

从MemoryHeapBase的构造函数中可以清楚地看到，其内部的核心就是Ashmem匿名共享机制，这也就解释了它为什么能实现跨进程的内存共享。关于Ashmen，我们在本书进程章节已经详细分析过，这里不再赘

述。

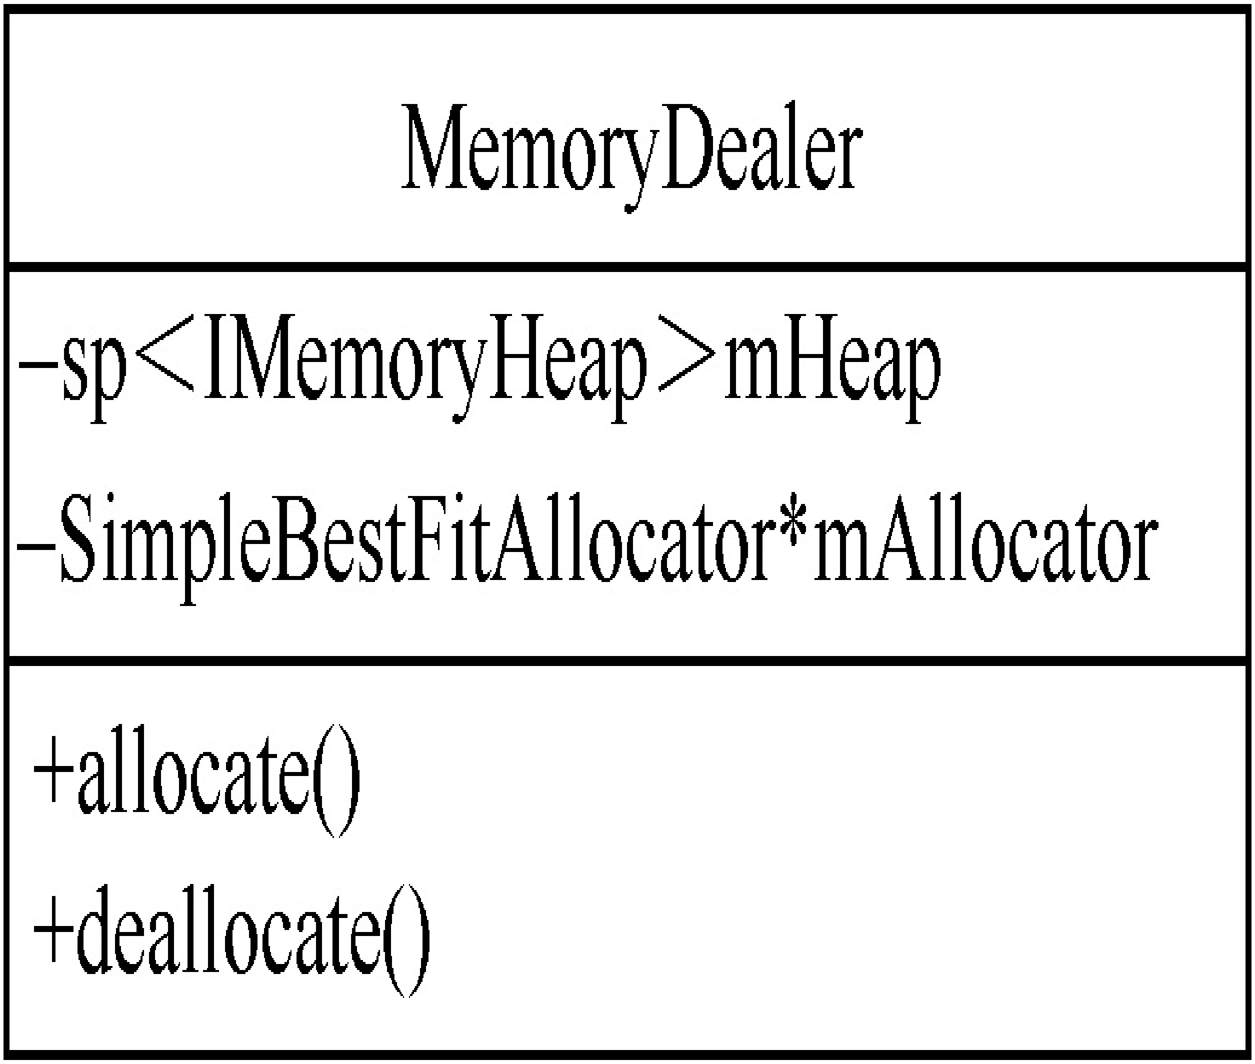

▲图13-27 MemoryDealer内部成员

这样通过Ashmen机制，AudioFlinger生成的内存缓冲区就能轻松实现与AudioTrack的跨进程共享，并通过Mutex和Condition来保证它们的互斥访问。

13.6.3 AudioMixer中的音频流

AudioMixer是由PlaybackThread(MixerThread)生成的，因而与AudioFlinger属于同一个进程。那么它是与TrackBase共用音频数据缓冲区，还是会“另起炉灶”呢？

我们知道，AudioMixer内部有一个mState成员变量，最多达32路的Track数据就存储在其中的state_t::tracks[MAX_NUM_TRACKS]成员数组中。每个PlaybackThread::TrackBase在AudioMixer中对应tracks数组中的一个元素，即：

```
    struct track_t {
        …
        uint16_t    frameCount;
        …
        AudioBufferProvider*     bufferProvider;
        mutable AudioBufferProvider::Buffer buffer; // 8 bytes
        …
        const void* in;  // 缓冲区中的当前位置
        …
        int32_t*           mainBuffer;
        int32_t*           auxBuffer;
     …
    };
```

我们只保留与缓冲区相关的部分。

其中，bufferProvider是由AudioFlinger调用AudioMixer::setBufferProvider来赋值的。相关源码如下：

```
AudioFlinger::PlaybackThread::mixer_state AudioFlinger::MixerThre
        Vector< sp<Track>> *tracksToRemove)
{…
    sp<Track> t = mActiveTracks[i].promote();
    …
    Track* const track = t.get();…
    mAudioMixer->setBufferProvider(name, track);
}
```

PlaybackThread::Track本身就是一个AudioBufferProvider（因为TrackBase继承自Extended AudioBufferProvider）。换句话说，mState.tracks[name].bufferProvider指向的就是AudioFlinger中的整个Track记录。

AudioMixer有多个与process相对应的实现体，如processgenericNoResampling，processgenericResampling，process__OneTrack16BitsStereoNoResampling等。我们选取其中的一个来验证一下AudioMixer所用的数据缓冲区和AudioFlinger，

AudioTrack是否属于同一个:

```
void AudioMixer::process__genericNoResampling(state_t* state, int
{…
    uint32_t enabledTracks = state->enabledTracks;
    uint32_t e0 = enabledTracks;
    while (e0) {
        const int i = 31 - __builtin_clz(e0);
        e0 &= ~(1<<i);
        track_t& t = state->tracks[i];
        t.buffer.frameCount = state->frameCount;
        t.bufferProvider->getNextBuffer(&t.buffer, pts);
        t.frameCount = t.buffer.frameCount;
        t.in = t.buffer.raw;
        if (t.in == NULL)
            enabledTracks &= ~(1<<i);
    }
…
}
```

第一个while循环里，首先给tracks[]数组中所有处于enabled状态的元素赋值。由于bufferProvider已经在之前的setBufferProvider中被设置为一个PlaybackThread::Track，所以这个getNextBuffer的实现如下:

```
status_t AudioFlinger::PlaybackThread::Track::getNextBuffer(Audio
Buffer* buffer, int64_t pts)
{
    audio_track_cblk_t* cblk = this->cblk();
    uint32_t framesReady;
    uint32_t framesReq = buffer->frameCount; //获取空间大小
    …
    framesReady = mServerProxy ->framesReady(); /*数据是否已经准备就
                                                   是指“消费者”*/
    if (CC_LIKELY(framesReady)) { //准备就绪
        uint32_t s = cblk->server; //“消费者”使用server指针
        uint32_t bufferEnd = cblk->serverBase + mFrameCount;
        bufferEnd = (cblk->loopEnd < bufferEnd) ? cblk->loopEnd :
        if (framesReq > framesReady) {//当前的可读数据比请求量少
            framesReq = framesReady;
        }
        if (framesReq > bufferEnd - s) {//会超过缓冲区尾部
            framesReq = bufferEnd - s;
        }

        buffer->raw = getBuffer(s, framesReq);
```

```
        buffer->frameCount = framesReq;
        return NO_ERROR;
    }
   …
}
```

整个处理流程和我们前面小节分析AudioTrack如何写缓冲区数据类似，读者可以自行理解。需要关注的重点是，函数参数中的buffer是由AudioMixer请求的缓冲区地址，从其中的实现来看它的确是由cblk计算出来的。也就是说，AudioMixer中用于混音操作（process_XX）的缓冲区对象和AudioTrack，AudioFlinger中的数据区确实是同一个。

13.7 音量控制

本小节以音量按键的处理过程为契机，来简要分析Android系统中音量控制的实现。相信这也是很多人关心的问题——特别是对于设备生产商（比如手机）来说，音量的调节处理还是比较重要的。

当用户按下音量调节键时（比如音量+），对应的keyEvent是：

```
public class KeyEvent extends InputEvent implements Parcelable {
      …
    public static final int KEYCODE_VOLUME_UP = 24;
```

系统中的多个地方都可能会处理这一事件，比如下面这两种情况。

1. AudioManger

略去中间的流转过程，我们直接看看AudioManager.java对这一事件的处理：

```
    public void handleKeyDown(KeyEvent event, int stream) {
        int keyCode = event.getKeyCode();
        switch (keyCode) {
            case KeyEvent.KEYCODE_VOLUME_UP:
            case KeyEvent.KEYCODE_VOLUME_DOWN:
                   …
                if (mUseMasterVolume) {
                         …
                } else {
                   adjustSuggestedStreamVolume(keyCode == KeyEven
                               ? ADJUST_RAISE: ADJUST_LOWER, stre
                }
                break;
            …
```

这个函数很简单，它根据“音量+”或者“音量—”进一步调用下面的函数：

```
public void adjustSuggestedStreamVolume(int direction, int sugges
          int flags) {
        IAudioService service = getService();
        …
        service.adjustSuggestedStreamVolume(direction, suggestedS
```

```
        …
    }
```

其中getService将得到名为Context.AUDIO_SERVICE=“audio”的Binder服务，具体对应的是SystemServer.java中添加的AudioService。因而上面adjustSuggestedStreamVolume的Server端实现如下：

```
/*frameworks/media/java/android/media/AudioService.java*/
    public void adjustSuggestedStreamVolume(int direction, int su
        int streamType;
        if (mVolumeControlStream != -1) {
            …
        } else {
            streamType = getActiveStreamType(suggestedStreamType)
        }
        …
        if (streamType == STREAM_REMOTE_MUSIC) {
            …
        } else {
            adjustStreamVolume(streamType, direction, flags);
        }
    }
```

我们知道，Android中将声音分为STREAM_MUSIC，STREAM_VOICE_CALL等多种流类型。那么当用户按下音量调节按键（音量+/）后，具体针对的是哪一种呢？这就是getActiveStreamType所要做的工作。从字面意思就可以猜测到，这个函数用于获取当前活跃的Stream类型——它首先判断当前是不是在通话中。如果回答是肯定的，再进一步判断是通过Speaker还是蓝牙进行的；又或者当前如果不在通话状态，则判断是否在播放音乐等。借助于getActiveStreamType，用户可以很方便地设置不同场合下的音量大小。

函数adjustStreamVolume的源码实现我们稍后讲解。

2．interceptKeyBeforeQueueing@PhoneWindowManager.java

对于部分重要的物理按键（比如HOME和音量调节键），系统会先判断它们是否需要做预处理，即interceptKeyBeforeQueueing。这个函数首先会根据当前的具体情况（是不是在通话状态、是不是在播放音乐等）来决定需要调整的STREAM类型，而且最后它会调用

AudioService.adjust StreamVolume——接下来的处理流程就和上面AudioManager中的情况一致了：

```
/*frameworks/media/java/android/media/AudioService.java*/
 public void adjustStreamVolume(int streamType, int direction, in
       …
       /*Step 1. 为各StreamType寻找Alias归类*/
       int streamTypeAlias = mStreamVolumeAlias[streamType];
       VolumeStreamState streamState = mStreamStates[streamTypeA
         /*Step 2. 为Stream Alias寻找匹配的device*/
       final int device = getDeviceForStream(streamTypeAlias);
       /*Step 3. 获取对应device的index*/
       final int aliasIndex = streamState.getIndex(device);
       boolean adjustVolume = true;
       int step;
       …
     step = rescaleIndex(10, streamType, streamTypeAlias);/*Step
      /*Step 5.音量调节对于音量模式的影响*/
      if (((flags & AudioManager.FLAG_ALLOW_RINGER_MODES) != 0)
               (streamTypeAlias == getMasterStreamType())) {
          …
      }

      /*Step 6.将音量调节事件发送给下一个处理者*/
      int oldIndex = mStreamStates[streamType].getIndex(device);
      if (adjustVolume && (direction != AudioManager.ADJUST_SAME
           if ((direction == AudioManager.ADJUST_RAISE) &&
                  !checkSafeMediaVolume(streamTypeAlias, aliasIn
               mVolumePanel.postDisplaySafeVolumeWarning(flags);
           } else if (streamState.adjustIndex(direction * step,
               sendMsg(mAudioHandler, MSG_SET_DEVICE_VOLUME,
                       SENDMSG_QUEUE, device, 0, streamState, 0)
           }
       }
       int index = mStreamStates[streamType].getIndex(device);
       sendVolumeUpdate(streamType, oldIndex, index, flags);
   }
```

这个函数看起来很长，但概括起来只有两个重点。即：

- 计算oldIndex（之前的音量值）、index（要调整的音量值）和flags。
- 调用sendVolumeUpdate和sendMsg把上一步的计算结果发送出去。

我们来分步看看它是如何计算出oldIndex和index的。

Step1@adjustStreamVolume。获取当前streamType对应的alias。虽然STREAM被划分为多种不同类型，但它们在某些方面的行为却是一样的。换句话说，可以对它们进行二次分类，这就是mStreamVolumeAlias数组的存在意义。

默认情况下，各类型STREAM的分组如下（在支持VOICE时）：

```
private final int[] STREAM_VOLUME_ALIAS = new int[] {
    AudioSystem.STREAM_VOICE_CALL,      // STREAM_VOICE_CALL
    AudioSystem.STREAM_RING,            // STREAM_SYSTEM
    AudioSystem.STREAM_RING,            // STREAM_RING
    AudioSystem.STREAM_MUSIC,           // STREAM_MUSIC
    AudioSystem.STREAM_ALARM,           // STREAM_ALARM
    AudioSystem.STREAM_RING,            // STREAM_NOTIFICATIO
    AudioSystem.STREAM_BLUETOOTH_SCO,   // STREAM_BLUETOOTH_S
    AudioSystem.STREAM_RING,            // STREAM_SYSTEM_ENFO
    AudioSystem.STREAM_RING,            // STREAM_DTMF
    AudioSystem.STREAM_MUSIC            // STREAM_TTS
};
```

右半部分的注释表示STREAM类型，左边的值是它们在alias数组中的组编号。比如STREAM_SYSTEM，STREAM_DTMF，STREAM_SYSTEM_ENFORCED就和STREAM_RING属于同一个组。

同一小组的stream state是一样的，由mStreamStates[]数组记录。

Step2@ adjustStreamVolume。根据stream alias来查询匹配的输出设备，我们在前几个小节已经有详细介绍，这里不再赘述。

Step3@ adjustStreamVolume。通过VolumeStreamState获得音量值（index），来看看这个函数：

```
    public synchronized int getIndex(int device) {
        Integer index = mIndex.get(device);
        if (index == null) {
            index = mIndex.get(AudioSystem.DEVICE_OUT_DEFAULT
        }
        return index.intValue();
    }
```

VolumeStreamState内部维护了一个mIndex数组来记录device对应

的index值。

Step4@ adjustStreamVolume。大家应该已经注意到了，当我们在调整音量时系统会有一个音量条出现，同时还伴随着短促的提示音——这样用户才能知道系统是否已经正确执行我们的音量调节命令。这一步就是在为UI显示条做前期准备。

Step5@ adjustStreamVolume。音量的调节还可能与手机的铃声模式（Ringer Mode）有关。

原生态系统中有如下几种模式：

```
    public static final int RINGER_MODE_SILENT = 0; //静音模式
    public static final int RINGER_MODE_VIBRATE = 1;//震动模式
    public static final int RINGER_MODE_NORMAL = 2;//正常模式
    private static final int RINGER_MODE_MAX = RINGER_MODE_NORMAL
```

比如当前是振动模式，那么当用户调整音量后，这一模式很可能被改变（当然，这取决于厂商制定的具体策略）。

Step6@ adjustStreamVolume。函数的末尾分别使用了两种方式来把音量调节命令进一步传递给后续的处理者——其中sendVolumeUpdate用于产生音量调节提示音并显示系统音量条；而sendMsg则会把命令投递到消息队列中，再由AudioHandler做进一步处理。AudioHandler除了将音量值保存到系统设置文件中外，还会调用AudioPolicyService的相关接口来真正调整音频设备的音量：

```
/*frameworks/av/services/audioflinger/AudioPolicyService.cpp*/
status_t AudioPolicyService::setStreamVolumeIndex(audio_stream_ty
index, audio_devices_t device)
{
    …
    if (mpAudioPolicy->set_stream_volume_index_for_device) {
       return mpAudioPolicy->set_stream_volume_index_for_device(m
       index, device);
    } else {
       return mpAudioPolicy->set_stream_volume_index(mpAudioPolic
    }
}
```

从前两个小节的分析中我们知道，mpAudioPolicy的默认实现是legacy_audio_policy中的audio_policy(Audio_policy_hal.cpp)，而

set_stream_volume_index_for_device实际上又调用了setStreamVolumeIndex@AudioPolicyManagerBase：

```
/*hardware/libhardware_legacy/audio/AudioPolicyManagerBase.cpp*/
status_t AudioPolicyManagerBase::setStreamVolumeIndex(AudioSystem
                                              int index, audio_de
{   …
    status_t status = NO_ERROR;
    for (size_t i = 0; i < mOutputs.size(); i++) {
       audio_devices_t curDevice =getDeviceForVolume(mOutputs.val
       if ((device == AUDIO_DEVICE_OUT_DEFAULT) || (device == cur
          status_t volStatus = checkAndSetVolume(stream, index, m
          if (volStatus != NO_ERROR) {
              status = volStatus;
          }
       }
    }
    return status;
}
```

因为系统中很可能有多个Output，每个Output又支持若干个device，所以上述代码段通过循环来查找所有匹配的设备，并通过checkAndSetVolume进行音量设置：

```
status_t AudioPolicyManagerBase::checkAndSetVolume(…)
{     …
     mpClientInterface->setStreamVolume((AudioSystem::stream_type
     …
```

变量mpClientInterface其实表示的就是AudioFlinger，因而绕了一圈最终还是由下面的函数来完成音量的设置，这也完全在我们的意料之中（因为AudioFlinger是执行者）：

```
status_t AudioFlinger::setStreamVolume(audio_stream_type_t stream
audio_io_handle_t output)
{…
    AutoMutex lock(mLock);
    PlaybackThread *thread = NULL;
    if (output) {
        thread = checkPlaybackThread_l(output);
        …
    }
    mStreamTypes[stream].volume = value;
    if (thread == NULL) {
       …
```

```
    } else {
        thread->setStreamVolume(stream, value);
    }
    return NO_ERROR;
}
```

首先根据output找到它对应的PlaybackThread，而后交由这个线程具体处理流的音量，同时把新的值记录到mStreamTypes中（注意：AudioFlinger和PlaybackThread各有一个mStreamTypes数组，不要搞混了）。

PlaybackThread究竟会如何处理这一音量变化，是在setStreamVolume吗？

```
void AudioFlinger::PlaybackThread::setStreamVolume(audio_stream_t
{
    Mutex::Autolock _l(mLock);
    mStreamTypes[stream].volume = value;
}
```

可以看到，PlaybackThread只是对音量值做了简单的记录，并没有做实际的动作。那么，音量的变化在什么时候才会生效呢？

还记得我们前面曾分析过的PlaybackThread::threadLoop这个函数吗？它在对音频数据进行处理前需要先调用prepareTracks_l来做准备工作。下面摘录与音量相关的那部分源码：

```
AudioFlinger::PlaybackThread::mixer_state AudioFlinger::MixerThre
        Vector< sp<Track>> *tracksToRemove)
{…
       float typeVolume = mStreamTypes[track->streamType()].volum
       float v = masterVolume * typeVolume;
       uint32_t vlr = proxy ->getVolumeLR();
       vl = vlr & 0xFFFF;
       vr = vlr >> 16;
      …
      mAudioMixer->setParameter(name, param, AudioMixer::VOLUME0,
      mAudioMixer->setParameter(name, param, AudioMixer::VOLUME1,
```

可以看到，之前setStreamVolume设置的音量值在这里会被提取出来，并和主音量等其他因素进行综合运算——这样得到的才是最终的音量值。紧接着这个值还会通过setParameter传给AudioMixer，以保证后者能根据当前音量做出正确的混音处理。

13.8　音频系统的上层建筑

13.8.1　从功能入手

到目前为止，我们已经详细分析了音频系统的底层实现，主要包括AudioTrack、AudioFlinger、AudioPolicyService以及HAL四个部分。基于这些基础再来理解音频系统的上层建筑，应该会轻松很多。接下来我们仍然遵循从整体到局部的内容编排顺序。

首先从功能的角度入手，看Android是如何规划音频系统的上层建筑的。

- 录制（Record）
- 相片拍摄/无声视频录制

  典型应用如“照相机”。

- 音频录制

  典型应用如“录音机”。

- 有声视频录制

  典型应用如“摄像机”（同时录制声音和视频）。

- 回放（Playback）
- 无声视频回放

  这种情况比较少见，即视频文件中不带音频信息。

- 音频回放

  比如音乐播放器。

- 有声视频回放

播放同时带有音视频的媒体文件。

看上去组合情况比较多，但对于应用开发人员来说真正需要关心的只有两类，即MediaPlayer和MediaRecorder。Android赋予了它们同时处理音频和视频的能力，使得我们在编写多媒体应用时可以把更多精力放在UI设计、功能实现与用户体验上，而不必涉及具体的音视频解码、显示、音频设备管理等细节。

我们用图13-28来概括Android系统中面向上层开发人员提供的整体功能设计。

接下来我们将分别介绍MediaPlayer和MediaRecorder。

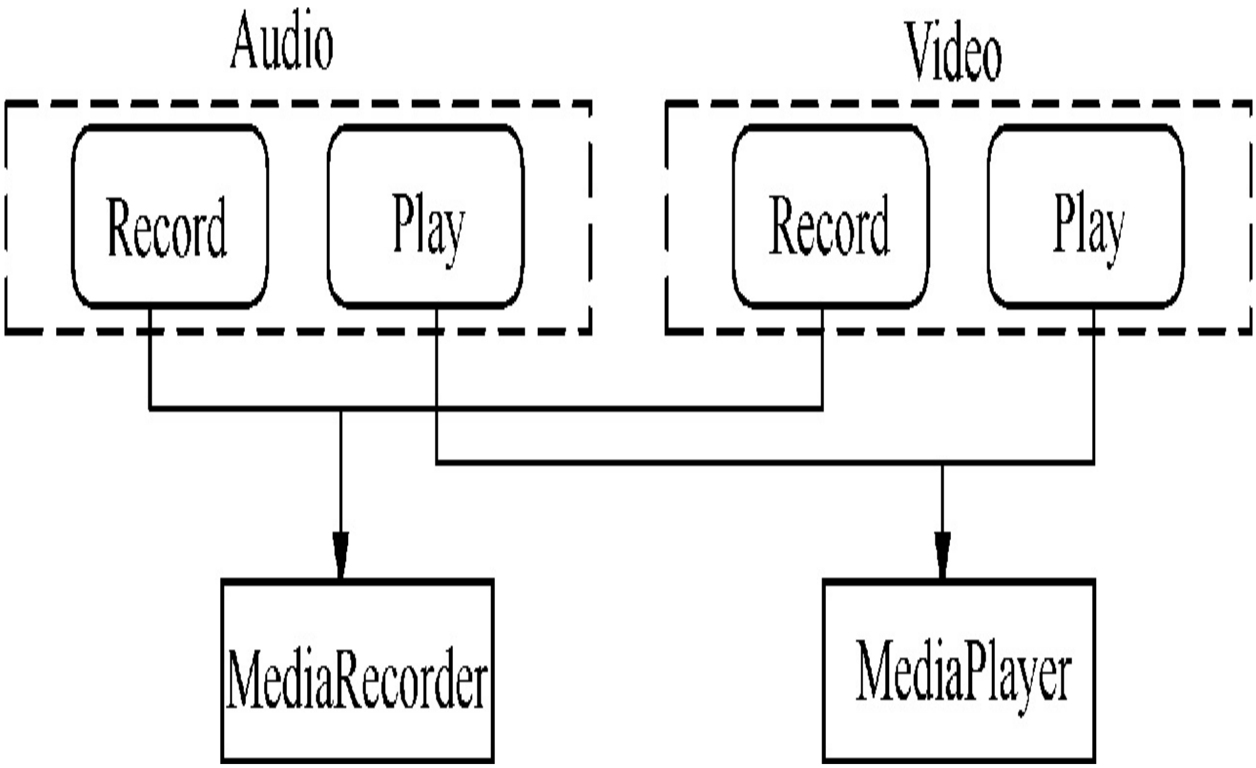

▲图13-28　多媒体功能概括

13.8.2　MediaPlayer

MediaPlayer是大部分应用工程师使用Android多媒体系统的直接入口。不论是音乐播放器、视频播放器，还是网络收音机（网络收音机本质上可以理解为一个“网络音频”的音乐播放器），或多或少都需要借

助于MediaPlayer来实现音视频的回放，如图13-29所示。

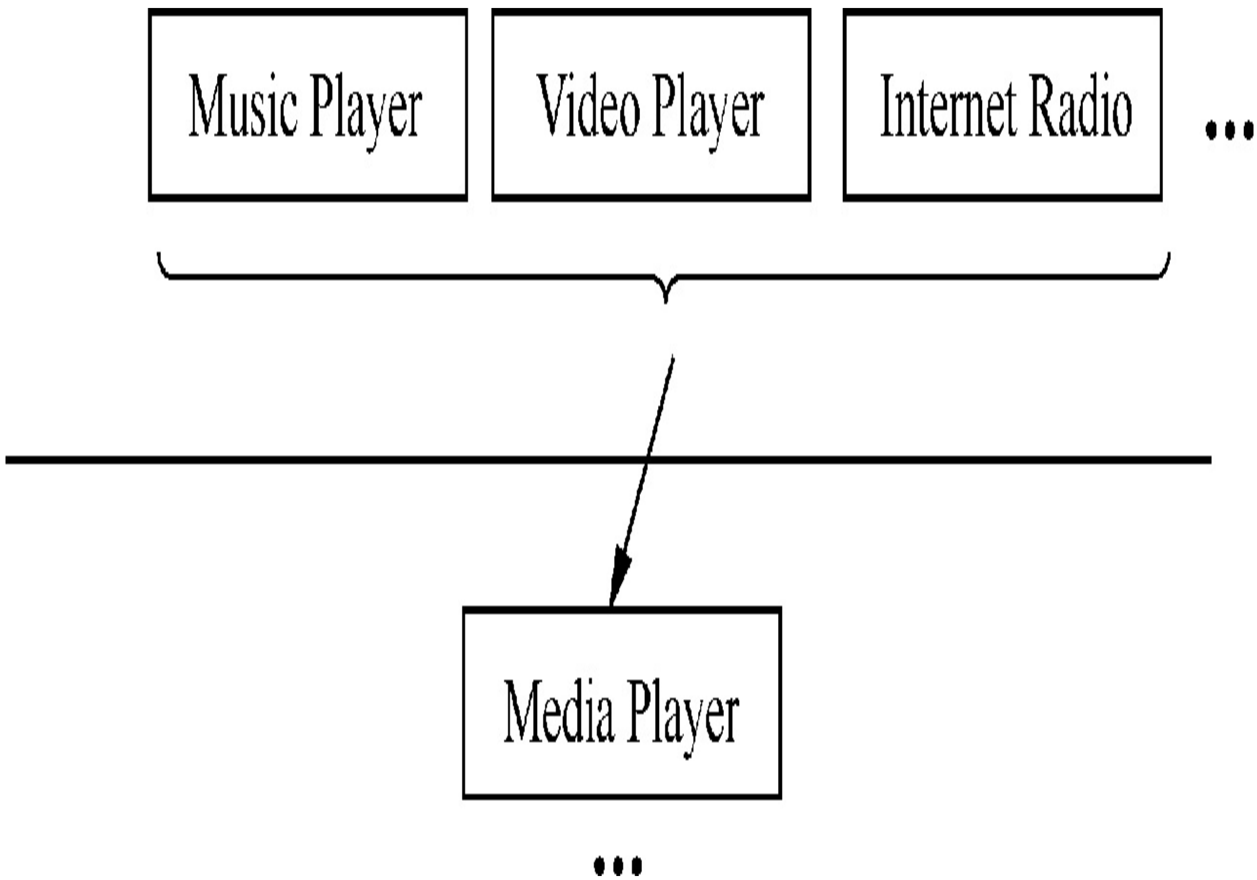

▲图13-29　MeidaPlayer与应用程序的关系图

1．MediaPlayer的状态迁移图

MediaPlayer只是一个状态机，它依赖于MediaPlayerService来完成具体功能——自身则不断向应用程序回馈当前的播放状况。

图13-30完整地描述了一个MediaPlayer实例的各种状态、触发事件以及迁移流程。

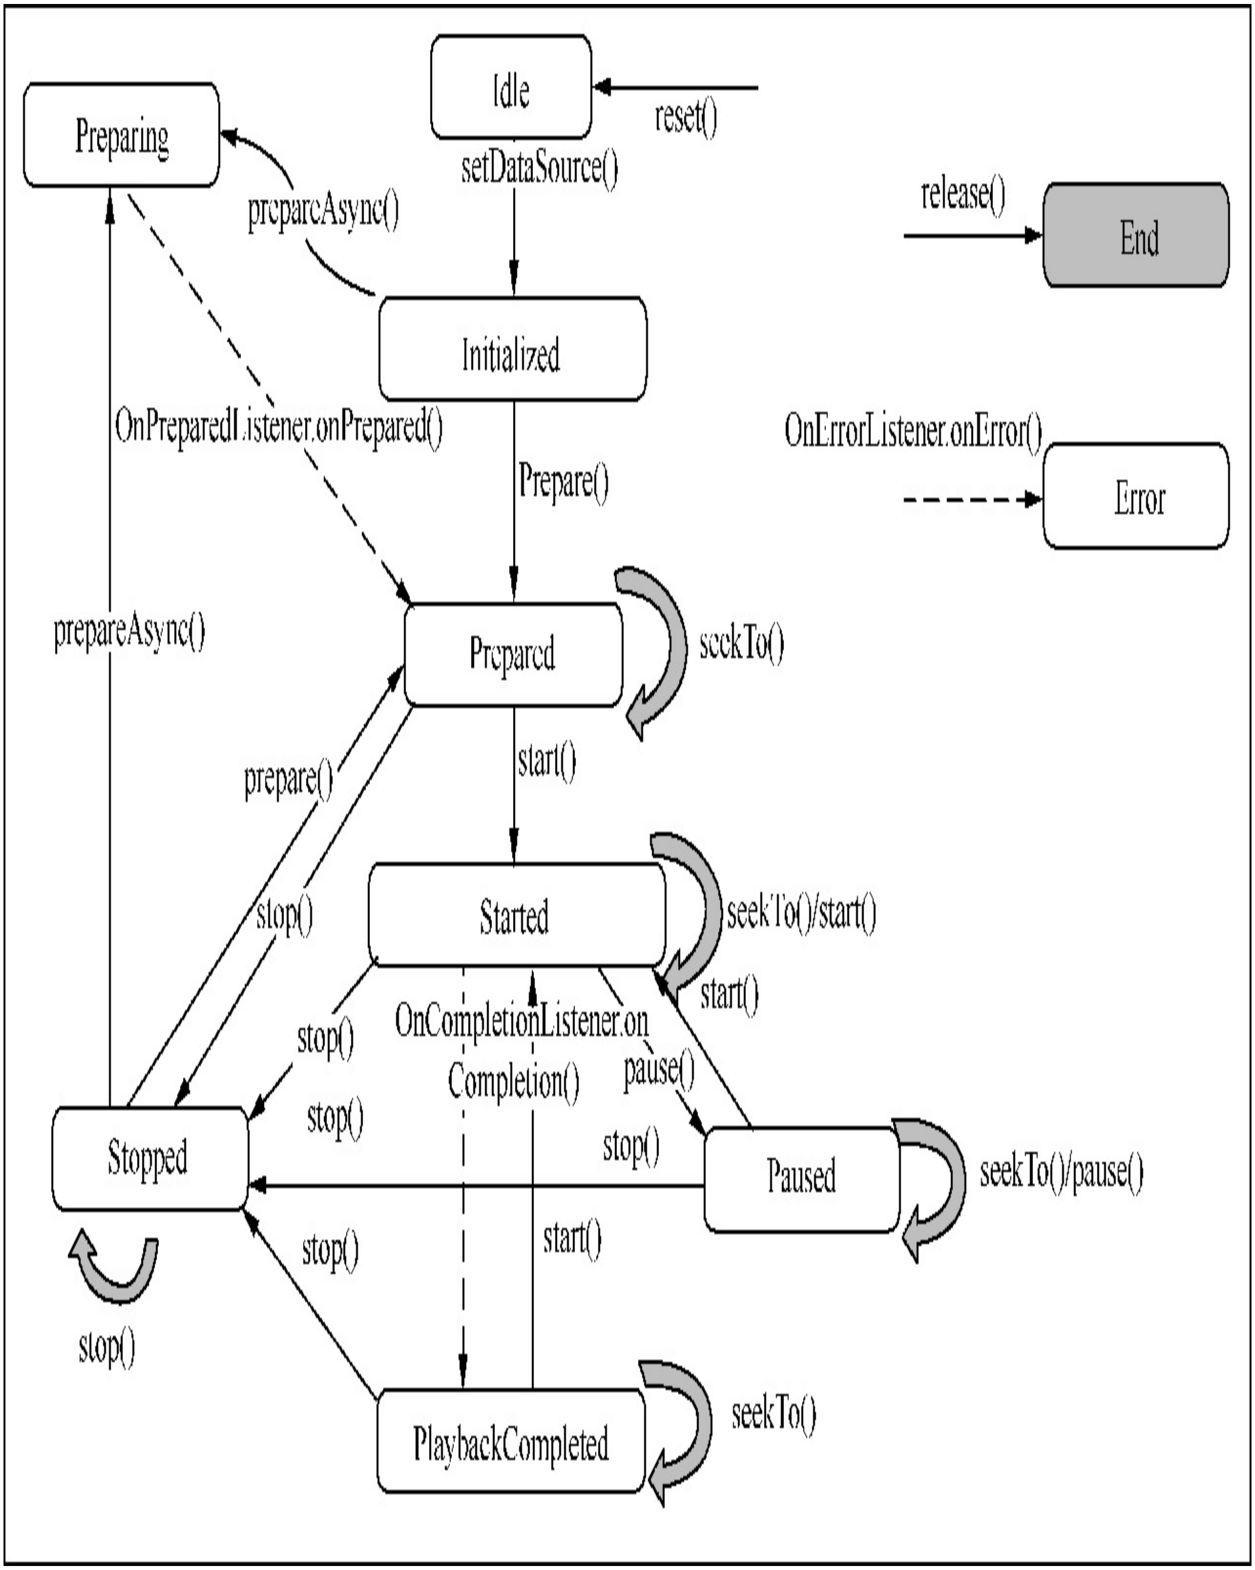

▲图13-30　MediaPlayer状态迁移图

图中的方框代表状态，实线箭头代表状态的触发条件（比如执行setDataSource这个函数将使播放状态从Idle向Initialized迁移），虚线箭头代表状态迁移时的回调（比如通过prepareAsync函数来准备数据，当数据就绪后将进入Prepared状态，且通过回调函数OnPreparedListener.onPrepared来通知应用程序）。

另外，在任何情况下有错误发生时，MediaPlayer的状态都会迁移到“Error”，同时回调OnErrorListener.onError()通知使用者；而且在任何时候调用release()，程序均进入End状态。

在状态机的约束下，所有跨状态的操作都是非法的。比如我们不能期望程序从Idle跨越Initialized直接进入Prepared——后者又是start()前必经的阶段。换句话说，在没有setDataSource()和prepare()/prepareAsync()前，MediaPlayer是绝对不允许程序直接调用start()的。关于MediaPlayer的更多状态控制细节，请读者自行参阅官方文档说明。

2．MediaPlayer的内部实现

既然MediaPlayer只是一个状态机，那么它是如何完成上层应用播放请求的呢？要解答这个问题并不难，只要看下它的Java层和Native层实现即可。

Java层显然只是一个简单的“中介”，代码片段如下：

```
/*frameworks/base/media/java/android/media/MediaPlayer.java*/
public class MediaPlayer
{…
    private native void _setDataSource(String path, String[] keys
        throws IOException, IllegalArgumentException, SecurityExc
        IllegalState  Exception;
    public native void prepare() throws IOException, IllegalState
    public native boolean setParameter(int key, Parcel value);
```

中间JNI层实现也相对简单，我们就不一一分析了，直接来看本地层的MediaPlayer(cpp)对象。以setDataSource为例，源码如下：

```
/*frameworks/av/media/libmedia/Mediaplayer.cpp*/
status_t MediaPlayer::setDataSource(const sp<IStreamSource>&sourc
{…
    status_t err = UNKNOWN_ERROR;
```

```
    const sp<IMediaPlayerService>& service(getMediaPlayerService(
    if (service != 0) {
        sp<IMediaPlayer> player(service->create(getpid(), this, m
        //在MPS中注册
        if ((NO_ERROR != doSetRetransmitEndpoint(player)) ||
            (NO_ERROR != player->setDataSource(source))) {
            player.clear();
        }
        err = attachNewPlayer(player);
    }
    return err;
}
```

首先当然还得获取MediaPlayerService的代理IMediaPlayerService，即getMediaPlayerService。这个函数无非就是通过ServiceManager来查找名为“media.player”的Binder服务，然后转化为Proxy对象。

接着调用如下语句：

```
sp<IMediaPlayer> player(service->create(getpid(), this, mAudioSes
```

这样MediaPlayerService就为这个MediaPlayer播放实例生成了一个“内部管理者”，并由IMediaPlayer来建立一条纽带。这是不是有点类似于AudioTrack与AudioFlinger间的IAudioTrack？

如果player变量没有发生错误，就可以把播放源设置进去，即player->setDataSource(source)。最后利用attachNewPlayer把这个Player与MediaPlayer(cpp)关联起来。如果一切顺利，状态机就会从Idle跳转到Initialized。如下所示：

```
status_t MediaPlayer::attachNewPlayer(const sp<IMediaPlayer>& pla
{
    status_t err = UNKNOWN_ERROR;
    sp<IMediaPlayer> p;
    { // scope for the lock
      Mutex::Autolock _l(mLock);
      if ( !( (mCurrentState &MEDIA_PLAYER_IDLE) || (mCurrentStat
       {
         return INVALID_OPERATION;//当前是否处于有效的状态
      }
      …
      mPlayer = player; //记录下IMediaPlayer，后续会经常使用到
      if (player != 0) {
```

```
            mCurrentState = MEDIA_PLAYER_INITIALIZED;//状态跳转成功
            err = NO_ERROR;
        } else {
            ALOGE("Unable to to create media player");
        }
    }
    …
    return err;
}
```

函数的一开头就对状态机进行合法性检查，因为并不是在所有状态下用户都可以调用setDataSource的，如果跨状态操作就会出错。各状态的enum值定义如下：

```
enum media_player_states {
    MEDIA_PLAYER_STATE_ERROR        = 0,
    MEDIA_PLAYER_IDLE               = 1 << 0,
    MEDIA_PLAYER_INITIALIZED        = 1 << 1,
    MEDIA_PLAYER_PREPARING          = 1 << 2,
    MEDIA_PLAYER_PREPARED           = 1 << 3,
    MEDIA_PLAYER_STARTED            = 1 << 4,
    MEDIA_PLAYER_PAUSED             = 1 << 5,
    MEDIA_PLAYER_STOPPED            = 1 << 6,
    MEDIA_PLAYER_PLAYBACK_COMPLETE  = 1 << 7
};
```

可见其与我们前面描述的状态迁移图是完全一致的。

关于MediaPlayer如何通过IMediaPlayer与MediaPlayerService开展通信，从而完成一系列复杂的播放控制，我们统一放在后续小节进行讲解。

13.8.3 MediaRecorder

MediaRecorder既可以录制音频，也可以录制视频。它和MediaPlayer一样，需要受到严格的状态机约束，如图13-31所示。

图13-31和前面的MediaPlayer状态迁移图大同小异，只是各个状态和触发条件有所差别，因而我们就不予详细描述了。

从硬件的角度来看，MediaRecorder将比MediaPlayer涉及更多的硬件设备，至少包括：

- 视频

通过视频录制设备（比如Camera）采集数据，并将采集到的图像显示在终端屏幕上实现同步预览，最后按照用户的要求保存到指定的存储设备（Flash、SD卡等）中。

- 音频

通过音频录制设备（比如MIC）采集数据，并按照用户的要求保存到指定存储设备中（如果是同时录制“音视频”的情况，则要将采集到的音视频数据进行统一存储）。

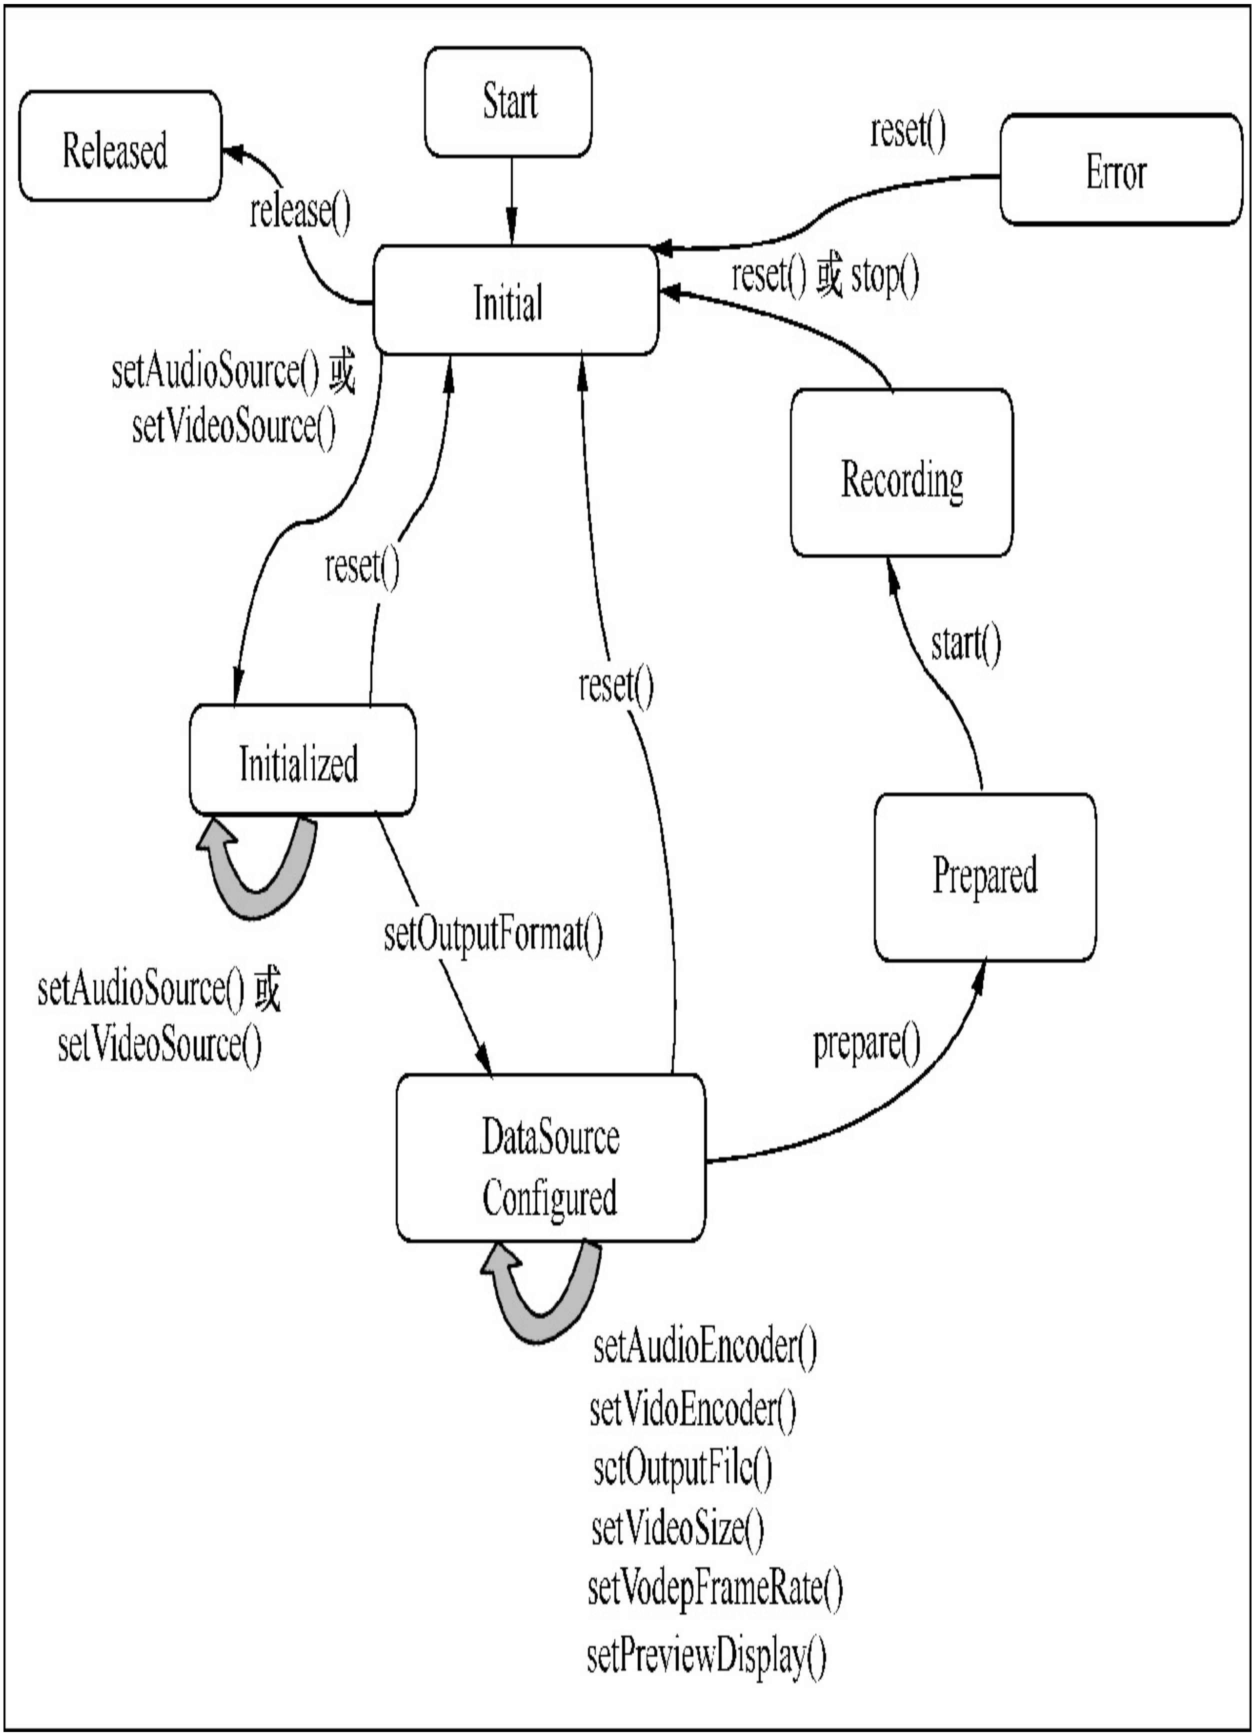
Start
Released
release()
reset()
Error
Initial
reset() 或 stop()
setAudioSource() 或
setVideoSource()
Recording
reset()
start()
reset()
Initialized
Prepared
setOutputFormat()
setAudioSource() 或
setVideoSource()
prepare()
DataSource
Configured
setAudioEncoder()
setVidoEncoder()
sctOutputFilc()
setVideoSize()
setVodepFrameRate()
setPreviewDisplay()

▲图13-31　MediaRecorder状态迁移图

- 编码器

在将音视频数据存储为文件之前，我们还需调用编码器对其进行先期处理。所以一个典型的有声视频的录制过程，需要使用到的硬件设备包含但不限于：Camera、Microphone、Screen、Storage、Codec，如图13-32所示。

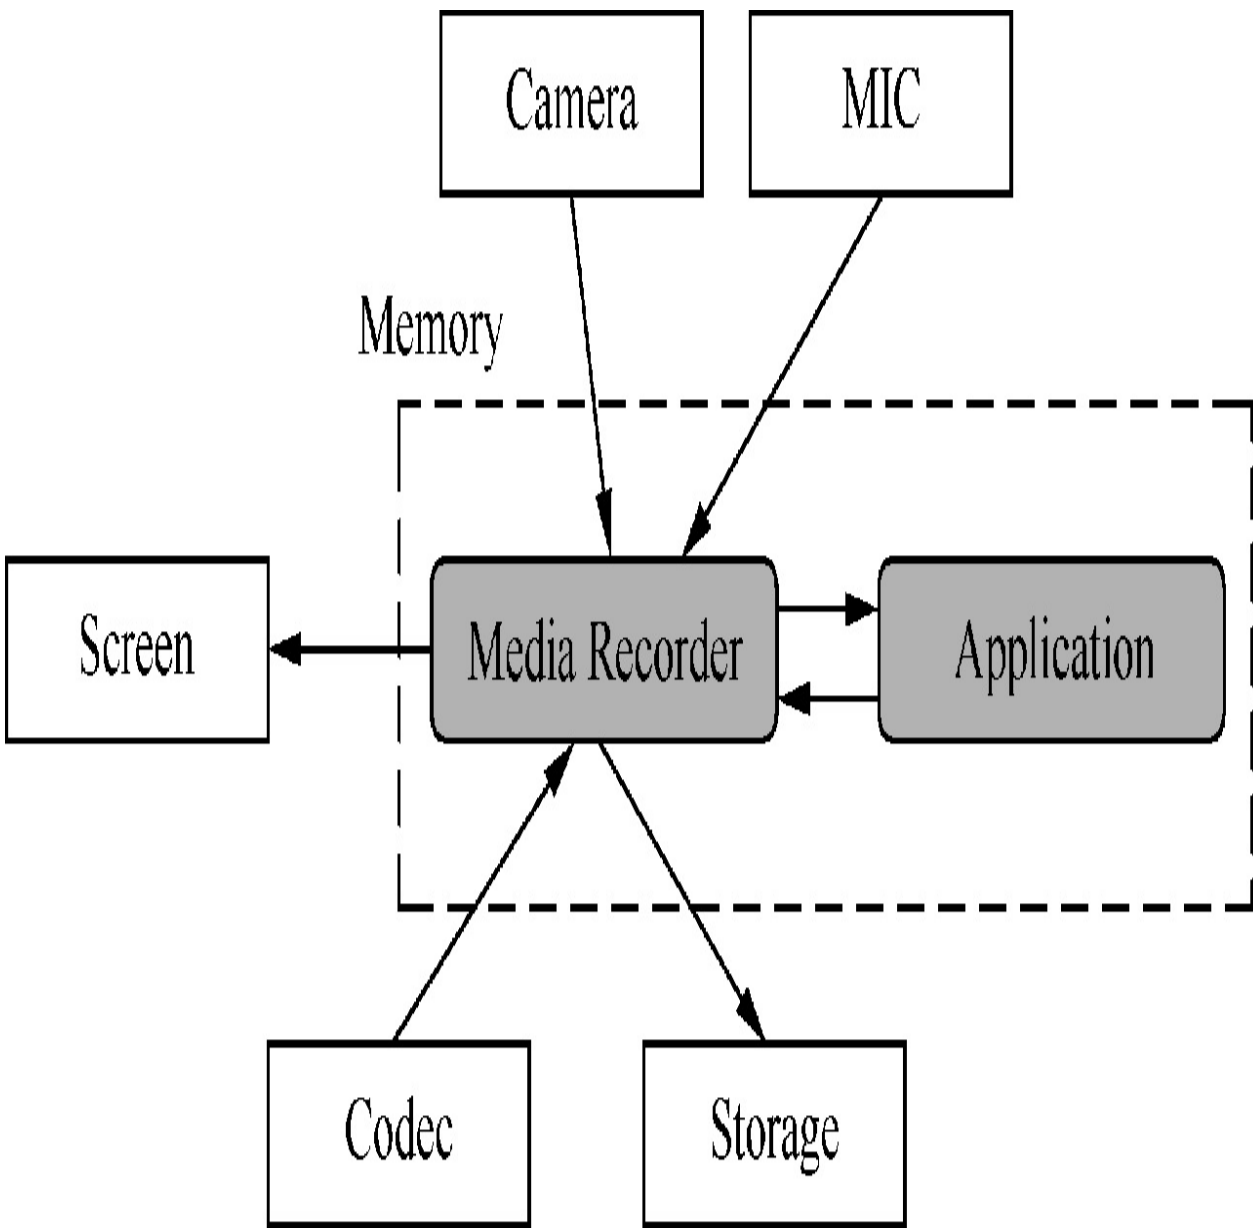

▲图13-32 从硬件角度理解MediaRecorder

可以设想一下，如果要求应用开发人员直接利用这些硬件设备来完成整个录制过程，将会是多么庞大的一项工程（如果真是这样，Android系统恐怕也不会得到如此迅猛的发展了——Android对硬件的控制和抽象封装非常有效。比如针对上面的硬件设备，Android提供了如下控制实现。

- 视频

开发者可以通过Camera类来轻松管理数据的采集流程，并且将这些数据与SurfaceView建立关联以实现终端屏幕预览。另外，还可以调用MediaRecorder的各种函数接口进行录制参数的配置及保存。

- 音频

同理，开发者只需通过MediaRecorder来配置音频录制所需的参数，如指定音频的编码格式、需要保存的路径等即可。系统会自动根据当前的硬件配置来调用音频采集设备，并将最终结果按照用户的要求保存下来。

- 编码器

不论是硬件还是软件编码器，都不需要应用开发人员去关心细节。他们唯一要做的就是通过MediaRecorder来设置参数。

由此可见，APK应用程序与MediaRecorder是“客户”与“服务提供商”的关系。或者更确切地讲，MediaRecorder是“采购人员”——应用程序只负责描述需求（通过MediaRecorder提供的各种设置函数），而MediaRecorder则负责根据这份需求清单在现有系统中“采购”相关设备，然后把这些设备协调起来去完成用户的要求，并且最大程度地让应用程序可以脱离其中的烦琐细节。

MediaRecorder和MediaPlayer一样，涉及的模块很多，可以说从应用层一直到Linux驱动层都需要有相应的支持。因而我们先提供一张完整的框架图来帮助大家更好地理解，如图13-33所示。

图13-33中：

- Media Application

录制音视频的APK应用程序，它是整个框架的发起者，亦是“录制需求”的制定者。

- MediaRecorder

它是应用程序的直接沟通者，也是框架的组织方。它在收到上层应用的需求后，协调其他所有模块来完成任务，并向应用程序汇报实时情况。

- MediaPlayerService (MPS)

简单地说，Android中的MPS是底层多媒体库的“代表”——这对于保持系统的可兼容性有重要意义。比如从Android 2.2开始，系统多媒体库实现已经从OpenCore逐渐过渡到了StageFright，而MPS的存在使得上层框架可以基本保持不变。

- StageFright

在Android新版的实现中，StageFright已经取代以往的OpenCore成为系统中唯一的多媒体库实现。我们在后续小节还会对它进行进一步分析。

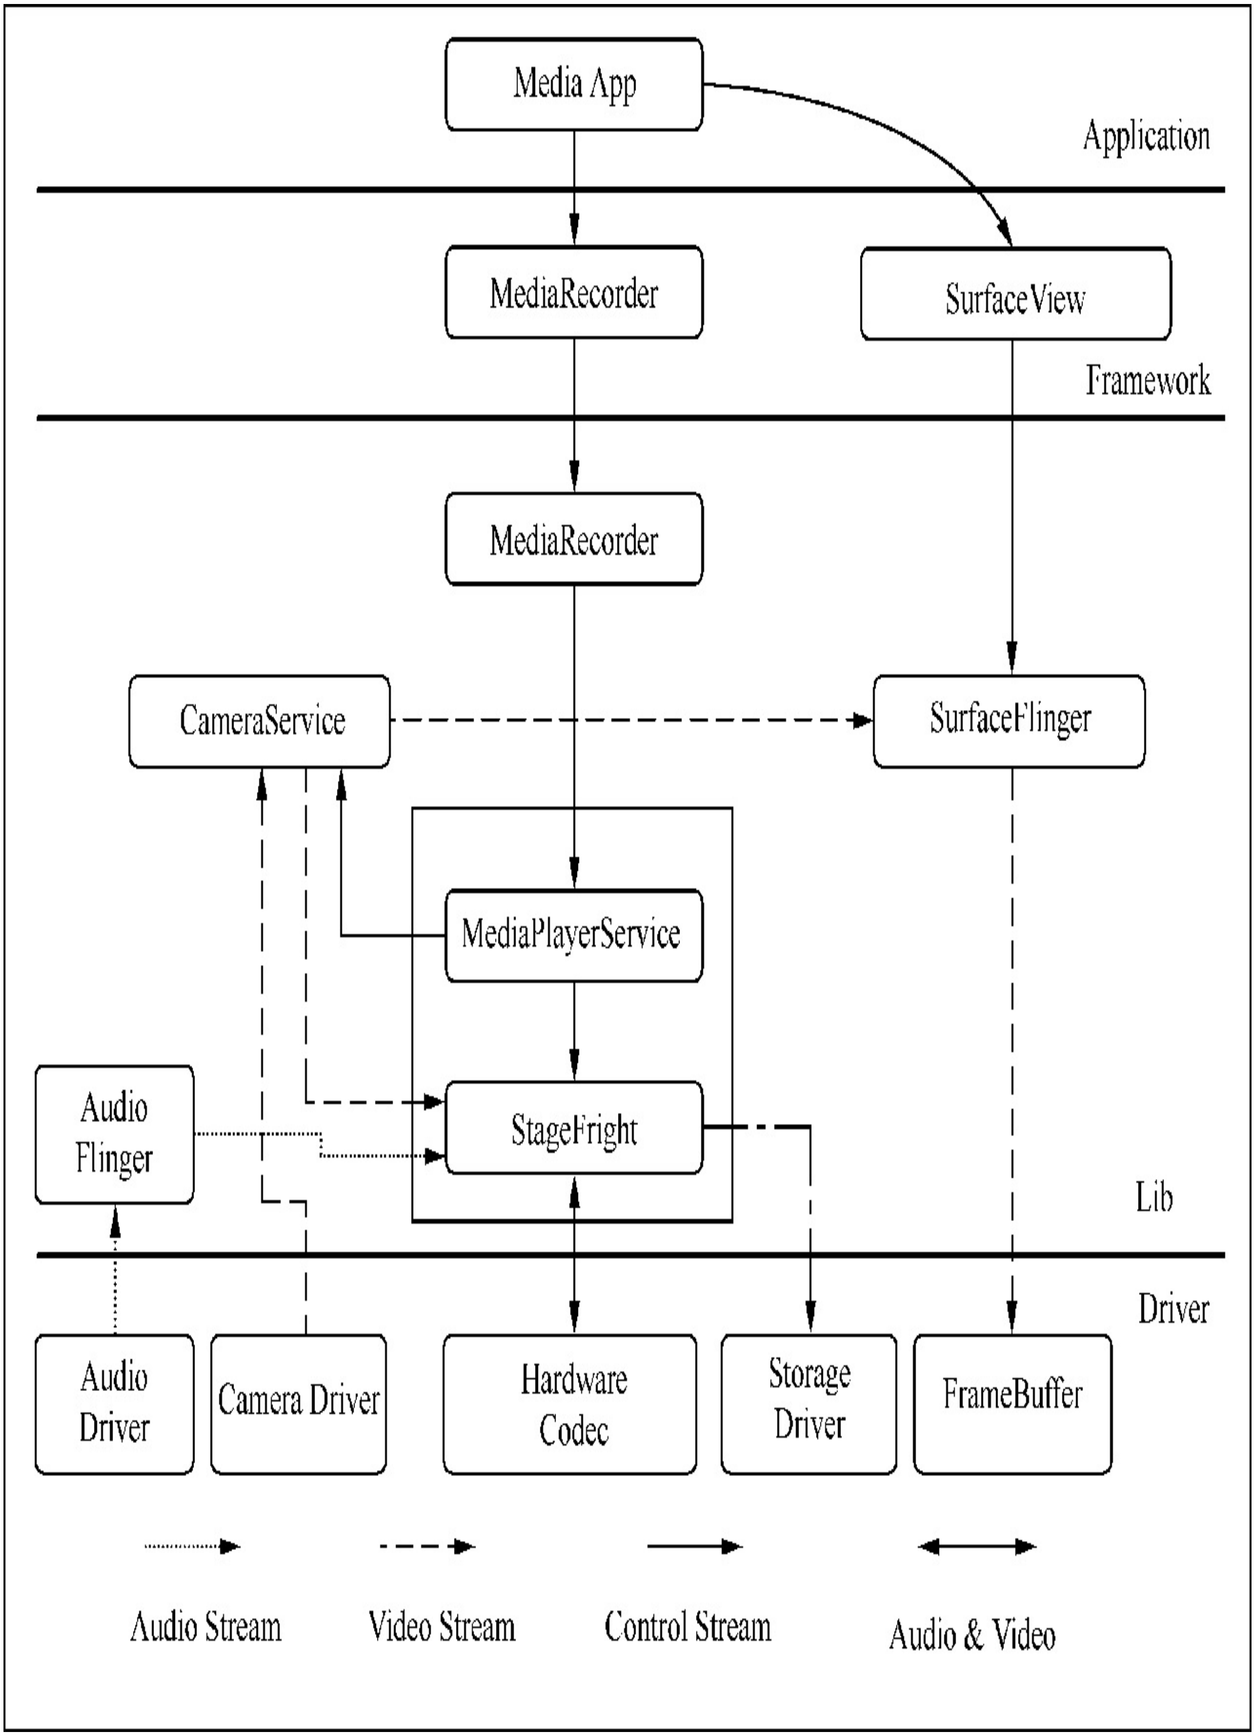

Media App
Application
MediaRecorder
SurfaceView
Framework
MediaRecorder
CameraService
SurfaceFlinger
MediaPlayerService
Audio Flinger
StageFright
Lib
Driver
Audio Driver
Camera Driver
Hardware Codec
Storage Driver
FrameBuffer
Audio Stream
Video Stream
Control Stream
Audio & Video

▲图13-33　MediaRecorder框架图

- VideoSource

一般情况下我们录制视频的来源是Camera，并且Android系统已经提供了成熟且丰富的android.hardward.Camera包来满足开发者对于Camera的各种常规需求。

- AudioSource

和视频源类似，录制音频同样也需要硬件采集设备。MediaRecorder支持多种类型的音频源，不过最常用的还是Mic。

- Preview

在视频录制的过程中进行同步预览也是必需的，这样才能让用户实时了解采集到的数据。Android系统提供的SurfaceView类可以方便地实现这一功能，同时结合OpenGL还可以对采集到的数据进行画面亮度、对比度等特效调整。值得一提的是，当程序通过MediaRecorder录制时，系统会强制要求用户提供一个有效的承载SurfaceView，因而一旦应用程序处于后台就无法完成正常的录制了。

接下来的内容安排如下。

- 通过一个有声视频的录制范例，让读者可以首先从应用层角度来了解MediaRecorder的使用方法。

- MediaPlayerService中与MediaRecorder相关的内部实现。

主要涉及如下几个目录的源码。

- frameworks\av\media\libmediaplayerservice;
- frameworks\av;
- frameworks\base\media。

13.8.4　一个典型的多媒体录制程序

我们先从应用开发层面来看看多媒体录制需要做哪些工作。下面的源码段展示了一个典型的“录像机”的工作流程：

```
Camera mCamera= null;
try {
    mCamera= Camera.open(); /*获取一个Camera实例。如果机器上有多
                           个Camera，可以在open时指定希望打开的那个Cam
}
catch (Exception e){
    /*如果当前Camera正在使用，将抛出异常*/
}

mMediaRecorder = new MediaRecorder(); /*实例化MediaRecorder，来自Me
mCamera.unlock(); //这一步是必须的
mMediaRecorder.setCamera(mCamera); /*MediaRecorder和Camera建立连接，
                                    集设备。这一设置将逐步往下传，直到
mMediaRecorder.setAudioSource(MediaRecorder.AudioSource.CAMCORDER
mMediaRecorder.setVideoSource(MediaRecorder.VideoSource.CAMERA);
               /*设置音视频的数据来源，这样MediaRecorder才知道应该从哪个
               Android目前支持的音频和视频来源请查阅后面的表格*/

mMediaRecorder.setProfile(CamcorderProfile.get(CamcorderProfile.Q
    /*设置音频和视频的编码器、输出格式、比特率等一系列参数。Android 2.2以前
mMediaRecorder.setOutputFile(getOutputMediaFile(MEDIA_TYPE_VIDEO)
    /*设置输出文件名、路径*/
mMediaRecorder.setPreviewDisplay(mPreview.getHolder().getSurface(

try {
    mMediaRecorder.prepare(); /*在Start以前必须先进行prepare*/
} catch (IllegalStateException e) {
    releaseMediaRecorder();
    return false;
} catch (IOException e) {
    releaseMediaRecorder();
    return false;
}
mMediaRecorder.start(); /*开始录制，屏幕上同时会显示视频图像的预览*/
…
```

目前系统支持的视频来源只有两种，即MediaRecorder.VideoSource.CAMERA和MediaRecorder.VideoSource.DEFAULT。

支持的音频来源类型较多，如表13-7所示。

表13-7　多媒体录制可选的音频来源

音 频 来 源	说　　明
CAMCORDER	和Camera相匹配的Microphone，否则就是设备的Main Microphone
DEFAULT	默认来源
MIC	Microphone
VOICE_CALL	语音通话
VOICE_COMMUNICATION	语音通信服务所配置的Microphone，如VoIP
VOICE_DOWNLINK	语音通话中下行部分音频（Downlink）
VOICE_UPLINK	语音通话中上行部分音频（Uplink）
VOICE_RECOGNITION	为语音识别服务所配置的Microphone，否则就按DEFAULT的情况处理

从这个范例可以看到，经过MediaRecorder的高度封装，应用程序

只需做简单的设置就可以很轻松地完成音视频的录制工作。MediaRecorder一方面提供了丰富的接口来满足用户的常规录制需求；另一方面很好地实现了模块的独立性，将诸如预览、Camera数据采集等工作完整地封装在多个系统Service和Binder服务接口中，为开发人员快速定制录制功能提供了有力的保障。

13.8.5 MediaRecorder源码解析

MediaRecorder源码主要由3部分组成。

- MediaRecorder.java

SDK中提供的面向APK应用程序的类实现。

- android_media_MediaRecorder.cpp

上述类接口的JNI实现。

- MediaRecorder.cpp

MediaRecorder的本地类，它负责与MediaPlayerService进行通信并确保具体功能的实现。

下面我们以MediaRecorder中的一个接口（即setPreviewDisplay）为线索，分析其内部的源码实现：

```
/*frameworks/base/media/java/android/media/MediaRecorder.java*/
public class MediaRecorder{
…
private Surface mSurface;
public void setPreviewDisplay(Surface sv) {
    mSurface = sv;//保存用户设置的Surface对象
}
}
```

上述mSurface只是MediaRecorder内部的成员变量，因而表面上看函数只是对变量进行了简单的赋值。线索似乎断了，其实不然，我们再来看以下代码：

```
/*frameworks/base/media/java/android/media/MediaRecorder.java*/
```

```
public class MediaRecorder
{
    static {
        System.loadLibrary("media_jni"); //加载MediaRecorder的JNI库
        native_init(); //这个初始化函数是一个本地实现
    }
    …
}
```

那么，native_init函数做了哪些工作呢？

```
/*frameworks/base/media/jni/android_media_MediaRecorder.cpp*/
static fields_t fields; //将MediaRecorder.java中的部分成员变量保存在这
static voidandroid_media_MediaRecorder_native_init(JNIEnv *env)
{
    jclass clazz;
    clazz = env->FindClass("android/media/MediaRecorder"); //找到M
    …
    fields.context = env->GetFieldID(clazz, "mNativeContext", "I"
    找到MediaRecorder(Java)对象中的mNativeContext成员变量*/
    …
    fields.surface = env->GetFieldID(clazz, "mSurface", "Landroid
    /*然后通过同样的方法找到    mSurface成员变量，也就是我们在setPreviewD
    变量，然后保存到fields中*/
    …
    jclass surface = env->FindClass("android/view/Surface");
    …
    fields.surface_native = env->GetFieldID(surface, ANDROID_VIEW_
     /*surface_native对应的是mSurface中的mNativeSurface域。前者是Java
      后者是Surface的本地实现*/
    …
}
```

通过JNI的特性可知，fields中的各变量与Java类中的域产生了关联。那么，fields.surface和fields.surface_native在什么时候产生作用呢？

```
/*frameworks/base/media/jni/android_media_MediaRecorder.cpp*/
static voidandroid_media_MediaRecorder_prepare(JNIEnv *env, jobje
/*还记得我们前面特别提醒过，应用程序在start()前必须要先调用prepare()吗?*/
{…
    sp<MediaRecorder> mr = getMediaRecorder(env, thiz); /*这里得到
    中创建的MediaRecorder(cpp)对象*/
    jobject surface = env->GetObjectField(thiz, fields.surface);/
    if (surface != NULL) {
        const sp<Surface> native_surface = get_surface(env, surfa
```

```
        …
        if (process_media_recorder_call(env,
                   mr->setPreviewSurface(native_surface->getIGrap
                  "java/lang/RuntimeException", "setPreviewSurfac
            return;
        }
    }
    process_media_recorder_call(env, mr->prepare(), "java/io/IOEx
                                     failed.");
    /*process_media_recorder_call是对执行结果(即它的第二个参数)的统一处
    比如失败时抛出异常*/
}
```

函数prepare()做了两件事。

- 向MediaRecorder(.cpp)设置PreviewSurface

也就是说，前面我们通过setPreviewDisplay设置的Surface，要直到prepare时才会真正被传递给MediaPlayerService。

- 调用MediaRecorder(.cpp)中的prepare()

先来看看MediaRecorder(.cpp)中一个关键的全局变量，如下所示：

```
/*frameworks/av/include/media/Mediarecorder.h*/
sp<IMediaRecorder>          mMediaRecorder;
```

这里的mMediaRecorder是应用程序与MediaPlayerService之间的桥梁。换句话说，到目前为止我们实际上还没有脱离应用程序本身的进程空间，真正跨进程的地方就发生在对这个变量的操作中。它是在MediaRecorder(.cpp)的构造函数里创建的：

```
/*frameworks/av/media/libmedia/Mediarecorder.cpp*/
MediaRecorder::MediaRecorder() : mSurfaceMediaSource(NULL)
{…
    const sp<IMediaPlayerService>& service(getMediaPlayerService(
    名向ServiceManager查询MediaPlayerService服务*/
    if (service != NULL) {
        mMediaRecorder = service->createMediaRecorder(getpid());/
        生成一个IMediaRecorder*/
    }
    if (mMediaRecorder != NULL) {
```

```
        mCurrentState = MEDIA_RECORDER_IDLE; //状态机开始运转
    }
    doCleanUp();
}
```

MediaPlayerService是如何生成这个IMediaRecorder对象的呢？

```
/*frameworks/av/media/libmediaplayerservice/MediaPlayerService.cp
sp<IMediaRecorder> MediaPlayerService::createMediaRecorder()
{…
    sp<MediaRecorderClient> recorder = new MediaRecorderClient(th
    实际上是一个MediaRecorderClient*/
    …
    mMediaRecorderClients.add(w);
    return recorder;
}
```

ImediaRecorder在MediaPlayerService中对应的实现类是MediaRecorderClient，它将承载后续应用进程中MediaRecorder向MediaPlayerService发起的各种业务请求。

回过头来看看MediaRecorder(.cpp)内部又是如何处理Surface的呢？

```
/*frameworks/av/media/libmedia/Mediarecorder.cpp*/
status_t MediaRecorder::setPreviewSurface(const sp<Surface>& surf
{…
    status_t ret = mMediaRecorder->setPreviewSurface(surface); /*
    PlayerService*/
    …
    return ret;
}
```

可见这和本小节开头给出的MediaRecorder框架图完全一致，即MediaPlayerService才是多媒体录制的核心，而MediaRecorder只是一个“协调者”。

我们来小结一下setPreviewSurface的处理过程。

- 应用程序通过MediaRecorder.java中的setPreviewSurface()设置一个Surface。通常Apk应用程序是通过在UI布局中添加一个SurfaceView组件来间接获取Surface对象。

- MediaRecorder的本地层实现，即android_media_MediaRecorder.cpp可以利用JNI特性访问到上一步骤中设置的Surface变量，并保存在自己的内部全局变量中。
- 当应用程序调用prepare@MediaRecorder时，JNI层的实现将间接调用setPreviewSurface@ MediaRecorder.cpp。
- MediaRecorder.cpp里持有和MediaPlayerService进行跨进程通信的代理，即：

```
sp<IMediaRecorder> mMediaRecorder;
```

通过这一变量，我们才将Surface最终传递给MediaPlayerService。

13.8.6 MediaPlayerService简析

和很多系统服务一样，MediaPlayerService也是在设备一开机时就启动的。具体而言，它属于mediaserver程序的一部分，而后者在系统第一个应用进程（init）解析的init.rc脚本中添加了启动项：

```
/*init.rc*/
service media /system/bin/mediaserver
    class main
    user media
    group audio camera inet net_bt net_bt_admin net_bw_acct drmrp
    ioprio rt 4
```

/system/bin目录下放置的是系统级的可运行程序，如mediaserver。我们在介绍AudioFlinger和AudioPolicyService时已经分析过这个程序，它的源码文件在工程的frameworks\av\media\mediaserver目录中。更多细节读者可以参考前面小节的介绍，这里不再赘述。

紧接着前面两个小节对MediaPlayer和MediaRecorder的讲解，我们来看看它们是如何与MediaPlayerService进行交互的。

1. MediaRecorder

前一小节中，createMediaRecorder()函数的任务是创建一个MediaRecorderClient对象，并返回给调用者，从而建立起它和

MediaPlayerService的远程通信。MediaPlayerService担负着录制、回放、编解码等一系列工作，因而MediaRecorderClient只是其中一个负责多媒体录制的实体。另外，创建出来的MediaRecorder通过如下语句保存进MediaPlayerService的全局管理中：

```
mMediaRecorderClients.add(w);
```

这也从侧面验证了MediaPlayerService是允许同时有多个Recorder（MediaPlayer也是同样的道理）存在的，只不过这样的情况并不多见。

因为是跨进程通信，可以猜想到MediaRecorderClient一定需要继承Binder的特性，如下所示：

```
class MediaRecorderClient : public BnMediaRecorder{…
}
class BnMediaRecorder: public BnInterface<IMediaRecorder>{…
}
```

BnInterface是一个模板类，定义如下：

```
template<typename INTERFACE>
class BnInterface : public INTERFACE, public BBinder{
…}
```

和Java不同，C++语言支持多重继承，因而最终MediaRecorder的继承关系如图13-34所示。

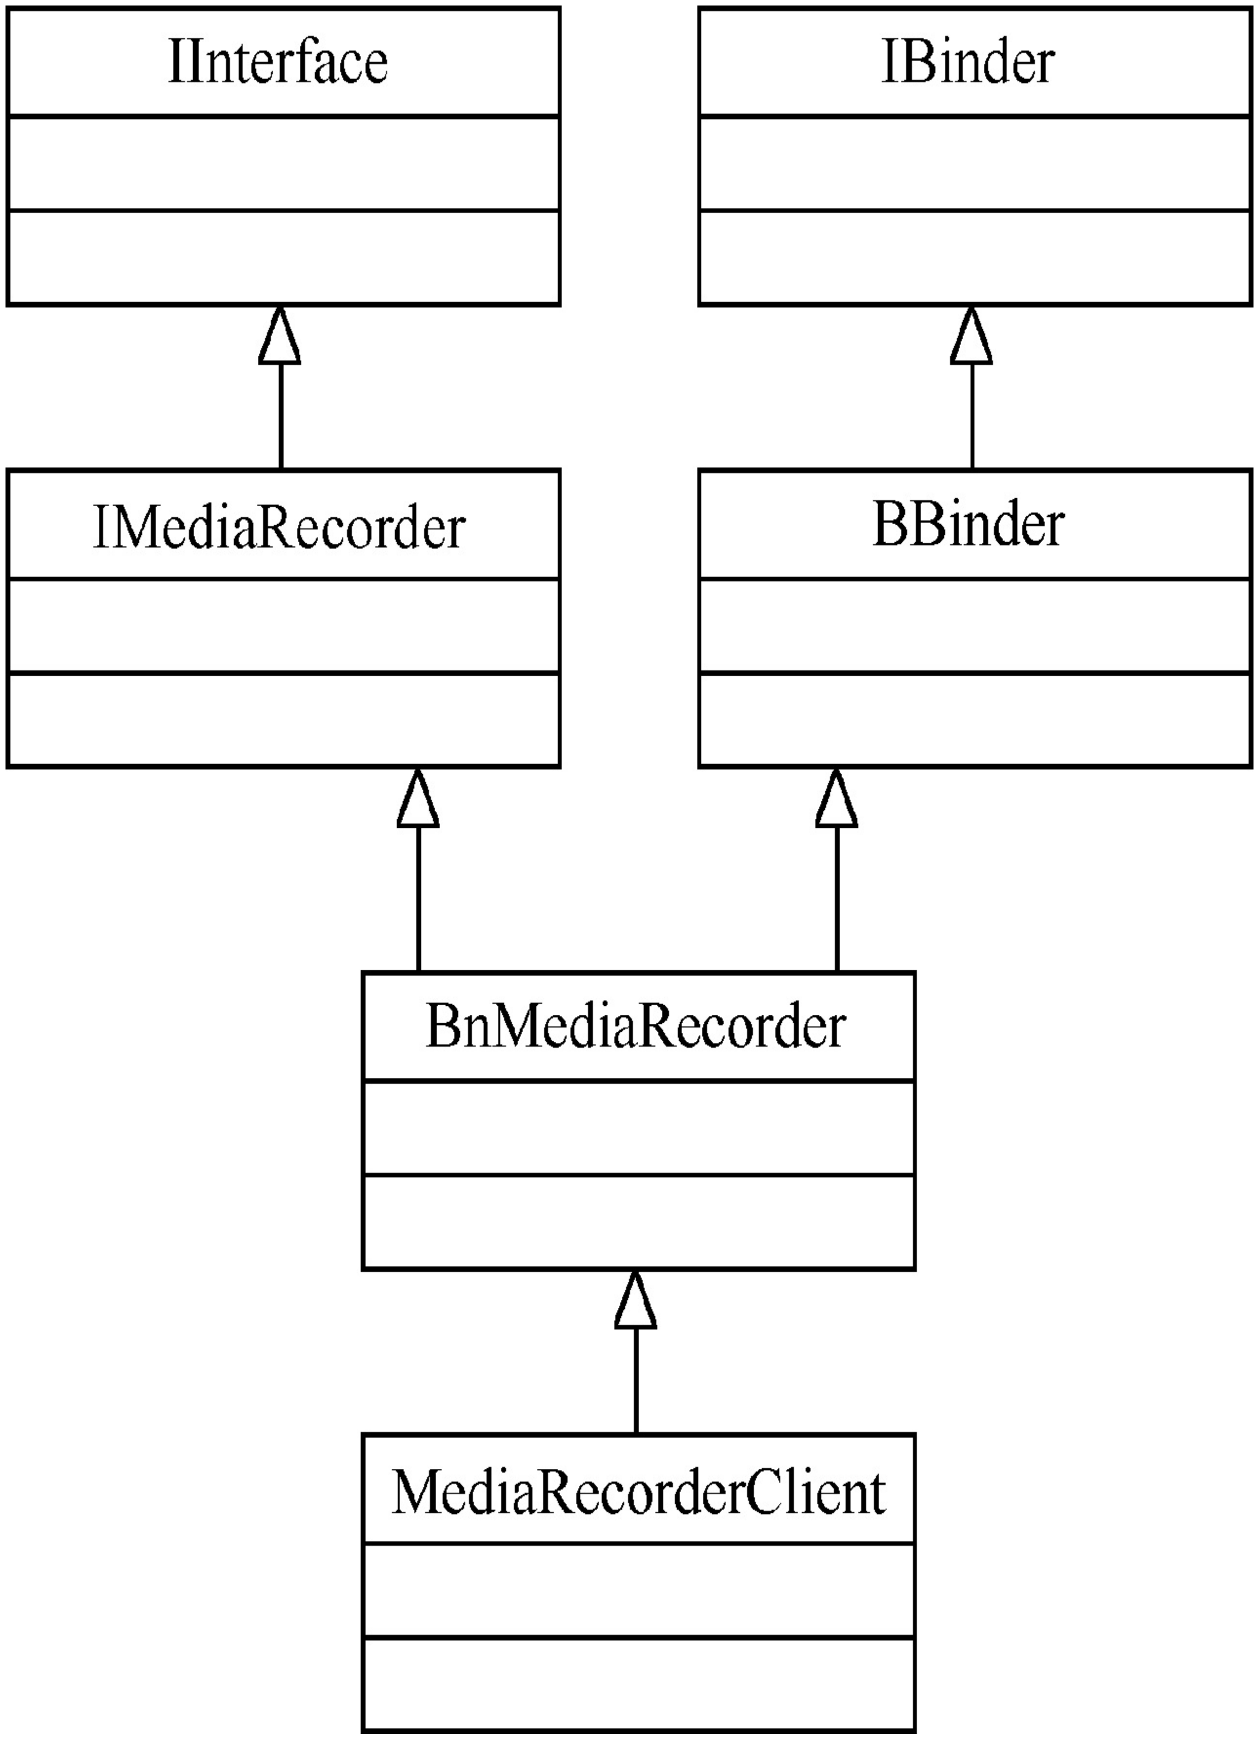
IInterface
IBinder
IMediaRecorder
BBinder
BnMediaRecorder
MediaRecorderClient

▲图13-34 MediaRecorderClient的继承关系图

其中，左边部分的IInterface体现了MediaRecorder提供的功能，而右边部分的IBinder则实现了它的跨进程能力。如果对这些基础知识还不是很清楚，强烈建议读者再回头复习下Binder章节。接下来的讨论中我们只关心IMediaRecorder这一部分的实现。

我们还是以setPreviewSurface这个接口为线索，帮助大家将整个流程串起来：

```
/*frameworks/av/media/libmediaplayerservice/MediaRecorderClient.c
status_t MediaRecorderClient::setPreviewSurface(const sp<Surface>
{
    Mutex::Autolock lock(mLock);
    …
    return mRecorder->setPreviewSurface(surface);
}
```

出现了一个mRecorder变量，来看看它的定义：

```
MediaRecorderBase *mRecorder;
```

MediaRecorderBase的作用可以理解为Java中的Interface，它提供了一种抽象的接口“协议”——不管最终的实现如何变化，其向外提供的功能都不变：

```
/*frameworks/av/media/libmediaplayerservice/MediaRecorderClient.c
MediaRecorderClient::MediaRecorderClient(const sp<MediaPlayerServ
{
    ALOGV("Client constructor");
    mPid = pid;
    mRecorder = new StagefrightRecorder; //StageFright终于出现了
    mMediaPlayerService = service;
}
```

从上面的代码段可以看到，MediaRecorderClient直接使用了StageFright，而没有根据条件做任何判断选择。这也进一步证明StageFright已经完全取代了OpenCore。

由于只是“中介”的角色，MediaRecorder本身并没有太多复杂的操作。值得一提的是，各芯片厂商（如三星、高通）在研发一款产品

时，通常会提供与平台硬件配置相匹配的Player/Recorder实现。这些扩展的Player/Recorder以原生态的StageFright为“蓝本”，并在此基础上迅速构建出更切合产品需求的播放器/录制器。

2．MediaPlayer

在MediaPlayer::setDataSource中有如下语句：

```
sp<IMediaPlayer> player(service->create(getpid(), this, mAudioSes
```

下面看看其具体的源码实现：

```
sp<IMediaPlayer> MediaPlayerService::create(const sp<IMediaPlayer
{
    pid_t pid = IPCThreadState::self()->getCallingPid();
    int32_t connId = android_atomic_inc(&mNextConnId);
    sp<Client> c = new Client(this, pid, connId, client, audioSes
    State::self()->getCallingUid());
    wp<Client> w = c;
    {
        Mutex::Autolock lock(mLock);
        mClients.add(w);
    }
    return c;
}
```

这个Client的命名容易让人产生歧义，实际上它和MediaRecorderClient类似，二者分别用于回放和录制操作。和MediaRecorderClient稍有不同的地方是，Client是MediaPlayerService的嵌套类——这可能是因为回放相对于录制功能没有那么复杂。

紧接着在setDataSource时，Client会根据请求的Source类型的不同来选择合适的播放器（除非系统属性“media.stagefright.use-nuplayer”强制要求使用NU_PLAYER，否则默认播放器类型是STAGEFRIGHT_PLAYER）——具体是由getPlayerType函数实现的，读者可以自行分析。目前系统支持的播放器包括：SONIVOX_PLAYER，STAGEFRIGHT_PLAYER，NU_PLAYER，TEST_PLAYER和PV_PLAYER。另外，和前述的MediaRecorder一样，芯片厂商有可能在此基础上扩展出自己的播放器类型。

在决定了使用哪个底层播放器后，Client会进一步通过createPlayer()来创建一个对应的Player实体。这和录制时的情况有很大不同，因为录制时我们直接就指定了StageFright。

对于大部分开发人员而言，StageFright底层库的源码实现并不是必须要掌握的。但它们可以辅助大家更好地理解多媒体框架，建议有兴趣的读者自行深入分析。

13.9　Android支持的媒体格式

本节将从音频、视频和网络流媒体3个方面来分析Android系统对媒体格式的支持情况。

13.9.1　音频格式

Android系统所支持的音频编解码器（Codec）及常见的文件格式（Container）如表13-8所示。请读者务必先理清编码格式和文件格式的区别，以免引起混淆。

表13-8　Android支持的音频编解码器

编解码器	编码	解　码	文件格式	说
AAC LC	Yes	Yes	• 3GPP（.3gp）• MPEG-4（.mp4，.m4a）• ADTS raw AAC（.aac，解码需要Android 3.1以上，编码需要Android 4.0以上版本，暂不支持ADIF）	支持单 声/5.0 样速率 48kHz
HE-AACv1 (AAC+)	Yes（4.1以上）	Yes		
HE-AACv2 (enhanced AAC+)	No	Yes		支持单 道/5.0 样速率 48kHz
AAC				支持单

ELD（enhanced low delay AAC）	Yes（4.1以上）	Yes（4.1以上）	• MPEG-TS（.ts，需要Android 3.0以上版本）	声采样 ～48k
AMR-NB	Yes	Yes	3GPP(.3gp)	支持音 4.75～ 样速率
AMR-WB	Yes	Yes	3GPP(.3gp)	音频码 23.85k 率：1
FLAC	No	Yes（Android 3.1以上版本）	FLAC (.flac)	采样速 48kHz 备本身 44.1kH 出，建 不超过 44.1kH
MP3	No	Yes	MP3 (.mp3)	支持单 声8～ 320kb 静态码 持VB 率）
MIDI	No	Yes	•类型0和类型1（.mid，.xmf，.mxmf）• RTTTL/RTX (.rtttl，.rtx)• OTA (.ota)•	支持： 0和类 本1和 和移动 声格式

			iMelody (.imy)	RTTT OTA
Vorbis	No	Yes	• Ogg (.ogg)• Matroska (.mkv， Android 4.0以上)	Vorbis 式相似 是开放 不涉及
PCM/WAVE	Yes(4.1以上)	Yes	WAVE (.wav)	8位和 PCM 取决于 备）头 8kHz、 44.1kH

13.9.2　视频格式

除了表13-9所列出的视频格式外，开发人员还可以通过导入第三方库来支持更多的视频编解码器功能。

表13-9　Android支持的视频编解码器

编解码器	编　　码	解　　码	文件格式	说明
H.263	Yes	Yes	• 3GPP (.3gp) • MPEG-4 (.mp4)	主要用于低码流通信
H.264	Yes（Android		• 3GPP (.3gp) • MPEG-4 (.mp4) • MPEG-TS（.ts，	低阶规格

AVC	3.0以上）	Yes	只支持AAC audio，需要Android 3.0以上版本）	Baseline Profile
MPEG-4 SP	No	Yes	3GPP (.3gp)	
VP8	Yes（4.3以上）	Yes（Android 2.3.3以上）	• WebM (.webm) • Matroska（.mkv，需要Android 4.0以上版本）	只在Android 4.0以上才支持流

13.9.3　图片格式

Android系统目前只支持常见的几种图片格式，如表13-10所示。

表13-10　Android支持的图片编解码器

编解码器	编　码	解　码	文件格式	说　明
JPEG	Yes	Yes	JPEG (.jpg)	Jpeg格式的图片
GIF	No	Yes	GIF (.gif)	Gif动态图片
PNG	Yes	Yes	PNG (.png)	PNG图片

BMP	No	Yes	BMP (.bmp)	BMP图片
WEBP	Yes（Android 4.0以上版本）	Yes（Android 4.0以上版本）	WebP (.webp)	Google推出的一种有损压缩图片格式，基于VP8

13.9.4　网络流媒体

Android系统是面向移动终端的，因而对网络协议格外重视。MediaPlayer便完整地封装了对多种网络流媒体协议的支持，包括但不限于：

- RTSP (RTP，SDP)

RTSP（Real Time Streaming Protocol）即实时流传输协议，是一种基于TCP/UDP的应用层协议。为了让读者对RTSP有个直观的认识，下面我们以场景对话（电影院）的形式来模拟协议流程。如下：

客户端：我想看《蜘蛛侠4》，有什么选择吗？

服务端：很多，比如2D的、3D的、IMax的……

客户端：我需要关于IMax的详细描述。

服务端：好的，它是这样的……

客户端：挺好的，我就要这个。你帮我出张票。

服务端：请问要什么时间段的、什么位置的，要不要VIP包间？

客户端：要最后两排的。

服务端：可以，请稍等……这是你的票，请收好。

客户端：明白，我要进去观看了。

服务端：好的，影片马上开始播放。

（影片放映中）

客户端：什么烂片，我不想看了。

服务端：好的，终止放映。

- HTTP/HTTPS progressive streaming
- HTTP/HTTPS live streaming draft protocol:
- 只支持MPEG-2 TS媒体文件
- Protocol version 3（Android 4.0以上版本）
- Protocol version 2（Android 3.x）
- Android 3.0以前的版本不支持
- Android3.1以前的版本不支持HTTPS

13.10 ID3信息简述

根据项目经验，开发人员在Android多媒体研发中经常会碰到一个知识点，即ID3。ID3是Android管理多媒体文件的重点之一（后续小节有介绍），因而我们在本小节做统一讲解。

在欣赏一首歌时，大家应该会留意到播放器上会显示诸如“标题”、“演唱者”、“专辑”等信息——它们可以让听众更好地了解这首歌曲。此类信息的来源有两个：其一是播放器从网络上直接下载获取的（当然，前提是你的设备能连接上网）；其二就来源于该音频文件自身储存的信息——ID3。

ID3通常用于MP3文件中，到目前为止有两个版本，即ID3v1和ID3v2。其中v2版本又分为若干个子版本。虽然ID3的使用非常广泛，但

至今还没有国际统一的ID3规范发布。换句话说，协议本身基本上属于开发者约定俗成的标准。

ID3的官方网址是：http://id3.org/。

ID3最初是由Eric Kemp于1996年首创的。当时MP3音频已经比较流行，却还没有通用的记录歌曲信息的方法。于是Kemp开创性地在MP3的文件末尾加入了一些数据，即后来的ID3v1。那么，为什么是加在文件尾部呢？这是为了兼容当时的主流播放器。可以想象，早期的播放器还不知道ID3的存在，当然无法解析出其中的数据含义。因而将ID3加在头部位置很可能导致这个音频文件被播放器误判为“无效”或者“损坏”。当然后期ID3流行起来后，播放器考虑到ID3的存在，也就不会有类似问题了。

ID3v1记录的信息相对简单，它占用的空间是固定的128字节，以“TAG”字符开头。剩余字节则用于描述如表13-11所示的一系列信息。

表13-11　　ID3v1中信息一览

域	长度（字节）	说　　明
Header	3	ID3v1版本的标志，即“TAG”
Title	30	标题信息
Artist	30	演唱者信息
Album	30	专辑信息
Year	4	年份

Comment	30	相关评论信息
Genre	1	流派信息

其中流派就有一百多种细分（包括WinAmp扩展的部分），我们就不一一列出了。

ID3v1的一个延伸版本是由Michael Mutschler在1997年提出的。他认为“Comment”部分并没有什么实际的用途，因此将其分出两个字节用于记录轨道数（Track Number），称为ID3v1.1。不过，这个版本用得并不多。

后来的几个版本改进主要是基于ID3v1容量太小的问题。因而人们想到分别将各个主要“域”进行扩容，如表13-12所示（共227字节）。

表13-12　扩展的ID3v1

域	长度（字节）	说　明
Header	4	扩展标志，即“TAG+”
Title	60	标题信息。注意“TAG+”并不覆盖“TAG”中的信息，而是在前述的基础上进行合并扩展。这就是说，一共有30+60个字节用于描述标题名，下同
Artist	60	演唱者信息
Album	60	专辑信息

speed	1	速度。0=unset，1=slow，2= medium，3=fast，4=hardcore
Genre	30	流派信息
Start Time	6	歌曲的开始时间，格式mmm:ss
End Time	6	歌曲的结束时间，格式mmm:ss

到1998年，ID3v2出现了。它和ID3v1在所描述的信息以及采用的数据记录格式等多个方面都发生了很大变化。具体如下所示：

- 数据存储位置差异

和V1版本的一个重要区别，就是ID3v2不再存放于文件尾部，而是头部。这主要是为了便于网络流媒体的播放。因为我们不可能等到媒体播放完再来显示它的相关信息，这显然是没有意义的。它以“ID3”为开头标志。

- 数据长度大小可变

前面说过，ID3v1中各域的大小是固定的。比如标题部分就只有那么大的空间，如果超过就不能完全容纳了；而有的信息却又不需要用那么多的字节来存储，从而造成了浪费——这些因素都导致ID3新版本采用了可变长度的存储方式。

- 文本编码格式

随着ID3使用范围的不断扩大，可以说它已经遍布全球，因而有必要考虑国际化因素。这就自然而然地牵扯到文本编码格式的问题。读者可以参阅本书应用篇中对编码格式以及Android系统中常见的一些文本

格式问题的详细介绍。

1．ID3v2 Header

ID3v2的头部格式如表13-13所示。

表13-13　ID3v2 Header

Name	Value	Description
ID3/file identifier	"ID3"	文件的头3个字节为固定值，表明是ID3v2版本
ID3 version	$XX XX（十六进制）	两个字节表示版本号。第一个字节是主版本号，第二个字节是修正版本号。所有修正版本都要求是向下兼容的，但是主版本则没有这个要求。两个字节都不能是FF
ID3 flags	%abc00000（二进制）	一个字节的标志位，用于表示是否有压缩、是否非同步等。不同版本的ID3的Flag是有差异的，可以参阅最新版本的ID3v2协议了解详情。以ID3v2.3为例，第一个bit表示Unsynchronisation，第二个bit表示Extended Header，第三个bit表示Experimental Indicator
ID3 size	4 * %0xxxxxxx	四个字节的Size值，用于表示整个Tag的大小（包括padding，但不包括头部10个字节）。由于每个字节的最高位都被置0，所以有效位数总共是4*7=28bit，即可以表达256M。举个

		例子，257个字节长的Tag表示为： $00 00 02 01

2．Extended Header

有没有“扩展信息”是可选的，播放器在解析ID3时可以从上面表格中的Flag里判断是否带有这一信息。Extended Header并不是很重要，目前大部分文件都没有附带扩展头，因而我们不过多介绍。

3．ID3v2 Frames

在ID3v2中，ID3 Tag是由一系列“frames”来描述的。每个Frame最大可达16MB，整个Tag的大小限制在256MB。目前最新的ID3v2中已经有多达84种Frame，而且应用程序也可以自定义Frame信息（尽管这种情况比较少，但并不是不可行。此时要特别注意避免Frame名称与其他人定义的重名）。

因为一个ID3 Tag中通常会带有多种Frame，所以同样需要有Header来描述它们。根据官方文档的解释，这个头信息格式如下：

```
Frame ID      $xx xx xx xx (four characters)
Size          $xx xx xx xx
Flags         $xx xx
```

Frame ID是由“A～Z”和“0～9”字符组成的。起初的ID3中Frame ID只允许3个字符，后来改为4个字符。其中“X～Z”这3个字符可以供个人使用，而不需要在ID3v2 Header中特别标注。Size域用于表示此Frame的大小，随后的Flags有两个字节——第一个字节用于表示“status messages”，第二个字节则用于编码说明。如下所示：

```
%abc00000 %ijk00000
```
第一字节第二字节

Frame Flags详解如表13-14所示。

表13-14　Frame Flags详解

Flags	Value	Description

a	0 Frame should be preserved 1 Frame should be discarded	如果该frame是unknown，该怎么处理？两个标志位在判断条件上略有差异
b		
c	1 Read only 0 Not Read only	只读标志位。如果说这个frame是只读的，那么随意更改很可能会破坏诸如签名等重要信息
i	0 Frame is not compressed 1 Frame is compressed using [#ZLIB zlib] with 4 bytes for 'decompressed size' appended to the frame header	压缩标志位
j	0 Frame is not encrypted 1 Frame is encrypted	加密标志位
k	0 Frame does not contain group information 1 Frame contains group information	是否和其他frames同属一个Group

虽然一般情况下我们会倾向于以优先级顺序来对Frame进行排列，但协议标准并没有强制要求这么做。一个Tag至少要包含一个Frame，而每个Frame又至少要有一个字节大小，且不包括头信息。

通常ID3数据编码采用的是ISO-8859-1，当然也可以使用Unicode。在Flags结束后的第一个字节，就用于表示这个Frame中数据所采用的编码方式。

```
0: ISO-8859-1
1: UTF-16
```

ID3v2.4版本中，还支持使用UTF-16BE和UTF-8等编码格式。

举个例子，图13-35所示是某MP3文件的ID3信息。

▲图13-35　MP3文件的ID3信息

按照前面的分析，这个范例中的Frame ID=TIT2，数据部分一共有7个字节，即：

“01FFFE00673172”。

它以01开头，因而是UTF-16。随后的FFFE表明它是Low Endian，因而实际上所表达的数据是：0x67007231——在Unicode码中，这个数字对应的字符是中文“最爱”。

其他Frame类型的解析都差不多，我们不再赘述。

13.11 Android多媒体文件管理

和Microsoft Windows等桌面型操作系统不同，Android系统主要面向终端设备，因而它的很多“行为”都是基于这一“场景需求”而设计的。例如，Android对多媒体文件的管理就契合了“移动终端”的特性。

Windows中所有文件类型都是趋于平等的，管理特定多媒体文件的工作通常由应用程序来完成。比如Windows MediaPlayer里会有用户喜爱的各种播放列表，或者将某个文件路径设为默认的乐曲存储目录。而Android系统作为嵌入式系统的一种，有其局限性。比如，没有鼠标、没有完整的键盘、屏幕相对于PC小、操作不便等。因而，它有必要为用户的常用功能提供足够的操作便利——基于这样的思想，由系统来统一管理多媒体文件就是必然的。

Android对多媒体文件的管理主要分为以下几部分工作。

- 扫描多媒体文件-MediaScannerService

扫描的对象包括内部和外部存储两种。它预先将设备中所有多媒体文件的信息（包括ID3）提取出来。这样当用户希望去访问这些文件或者读取文件的信息时，系统就可以做到快速响应；这也同时减轻了应用程序的负担，如APK播放器可以直接向系统查询当前有哪些mp3文件，而不需要再做耗时的扫描操作。这部分工作统一由MediaScannerService完成，它继承于BroadcastReceiver，后面会有更详细的介绍。

- 存储多媒体文件信息-MediaProvider

MediaScannerService得到的扫描结果如何存储，又怎么向用户提供查询呢？Android系统选择了ContentProvider的方式。这个组件专门用于数据进程间的共享，类似于“仓库”的概念。具体而言，存储多媒体文件信息的工作由MediaProvider来完成。

- 用户的查询入口-MediaStore

可能有读者会问，既然有了上面的MediaProvider，为什么还要有个MediaStore？它们之间是什么关系？举个例子，就比较容易理解了。

MediaStore从名称来看是商店的意思，那么当用户需要购买商品时（比如牙膏、牙刷这些生活用品），显然大都是通过Store来完成的（当然不排除个别人直接从厂家拿货）。但是牙膏和牙刷本身并不是商店生产的，商店只是为生产商提供了展示的柜台，让顾客和这些商品有一个统一的“接触点”。言下之意，对于没有在商店中摆放出来的商品，即便厂商有大批现货，顾客也买不到。MediaStore将所有的“商品”划分为如下几类。

- MediaStore.Files

  多媒体“仓库”中的所有文件，不论它们是不是多媒体文件。

- MediaStore.Audio

  音频文件都归于这一类。

- MediaStore.Video

  视频文件归类于此。

- MediaStore.Image

  图像文件的存储地。

因为不同类型的文件向外提供的Content Provider的URI是不一样的，所以每种类型的“仓库”都会提供一个getContentUri()的接口来告诉使用者其具体的引用位置。

从上面的解释可以看出，Android系统中的多媒体文件管理者实际上是一个“应用程序”，用到BroadcastReceiver，ContentProvider等组件。这就不难理解为什么它对应的源码大多在packages目录下了。

图13-36描述了多媒体文件管理的几个主要组成部分。

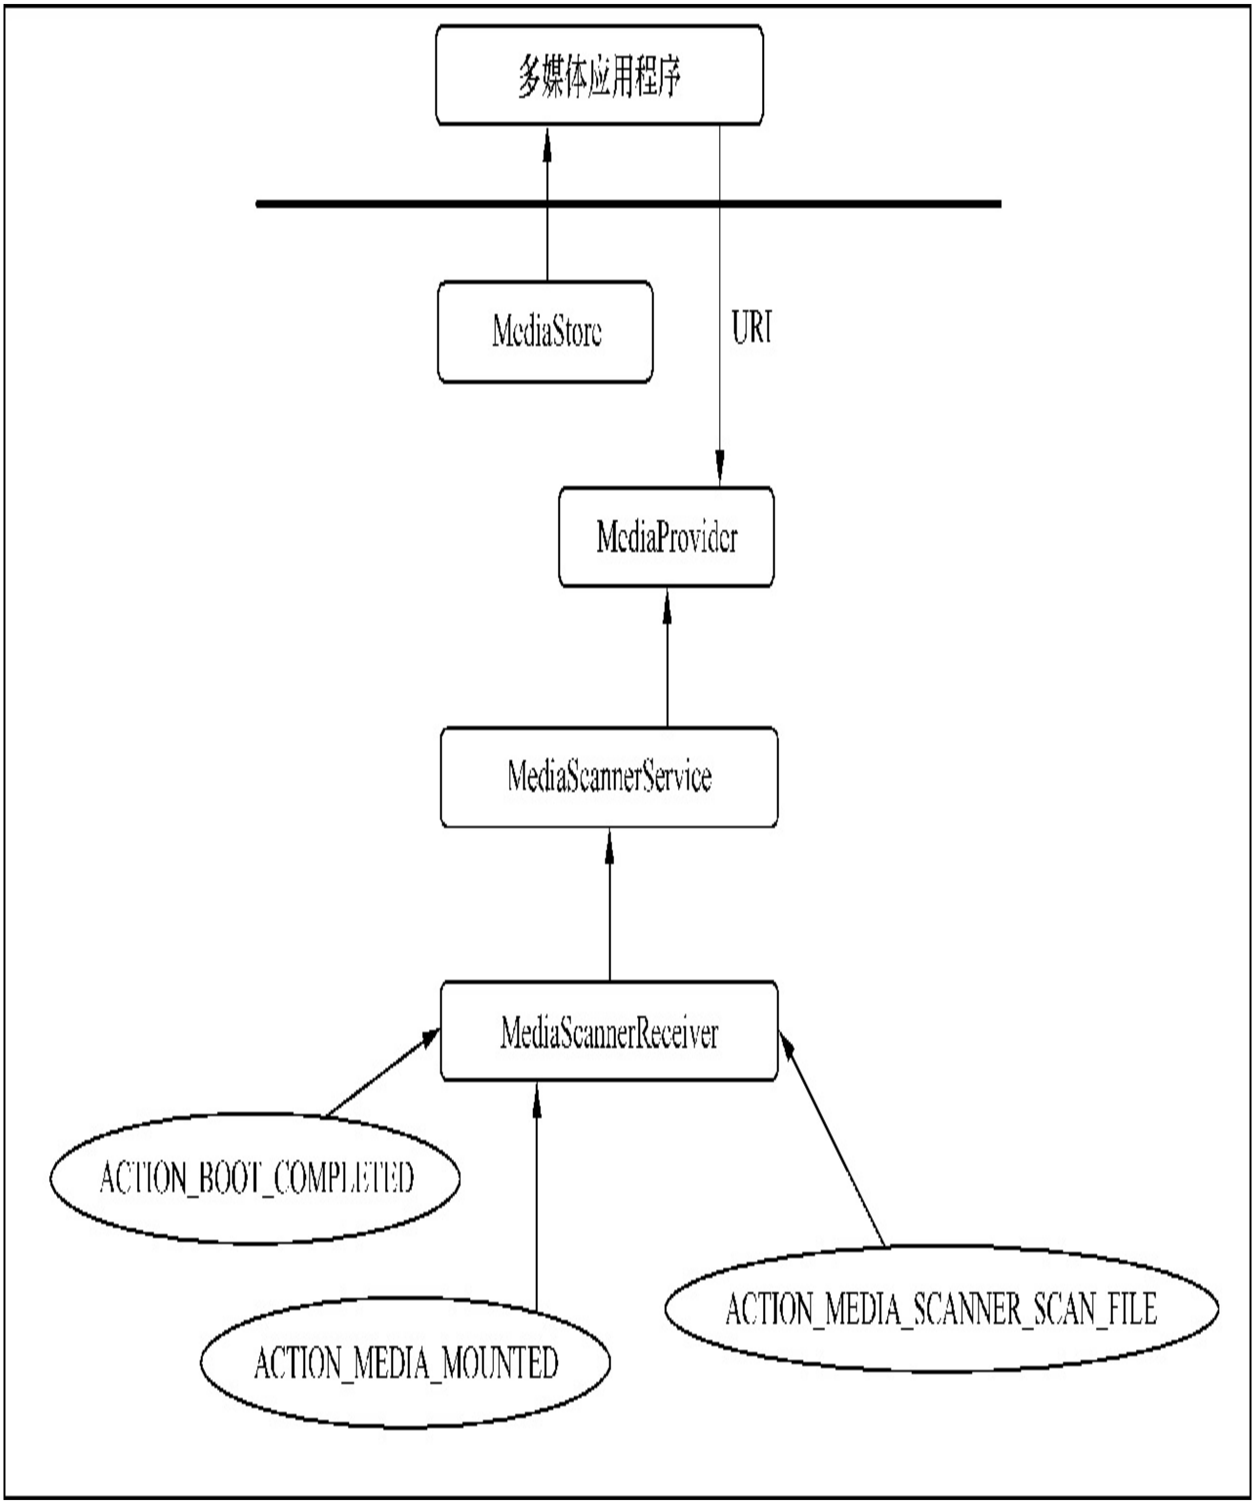

▲图13-36　多媒体文件管理

接下来我们将分别介绍这几个重要的组成部分。

13.11.1 MediaStore

“商店”的工作就是陈列物品，并对各厂商的产品进行统一管理以响应“用户”的需求，如查询、购买等。因而，它并不需要了解商品的设计原理和生产过程。

源码路径：frameworks\base\core\java\android\provider

MediaStore是面向应用程序的入口，所以它存放在frameworks中，并且作为SDK的一部分开放给应用开发者。

这个类里还包含几个子类，主要是完成上面所说的媒体类型划分。读者在下面这个代码段中可侧重看看每种类型的Content URI：

```
/*MediaStore.java*/
public final class MediaStore {…
    public static final class Files {
        public static Uri getContentUri(String volumeName) {
            return Uri.parse(CONTENT_AUTHORITY_SLASH + volumeName
          /* CONTENT_AUTHORITY_SLASH = "content://media /",因而Fil
             "content:// media /[volumeName]/file"*/
        }
    …}

    public static final class Images {/*Images还可以再分为Media和Thu
    public static final class Media implements ImageColumns {
    public static Uri getContentUri(String volumeName) {
        return Uri.parse(CONTENT_AUTHORITY_SLASH + volumeName +"/
         /*所以Media的URI为："content://media /[volumeName]/images/
    }
…}

public static class Thumbnails implements BaseColumns {
     public static Uri getContentUri(String volumeName) {
                return Uri.parse(CONTENT_AUTHORITY_SLASH + volume
                                      "/images/thumbnails");
             /*Thumbnails的URI为："content://media /[volumeName]/i
     }
…}
…其他类型是相似的，读者可以自己分析。
```

由上面的分析可以总结出MediaStore所提供的媒体类型的Content Uri格式。

content://media/[volumeName]/[media_type]/[sub_type]

其中：

- volumeName分为Internal和External两种。
- media_type即Files、Images、Audio、Video等媒体类型。
- sub_type是上述媒体类型的细化分类，如Images中的Media和Thumbnails。

MediaStore中描述的都是MediaProvider与应用程序间的接口内容，开发人员可以通过它来了解系统都提供了哪些Media分类以及各类中的一些详细信息。

下面我们将讲解MediaProvider具体是如何提供这些URI所指向的数据的。

13.11.2 多媒体文件信息的存储“仓库”——MediaProvider

MediaProvider是多媒体文件信息的存储“仓库”，因而不论是MediaScanner还是MediaStore，工作都是围绕这个Provider展开的。MediaProvider继承自ContentProvider，运行在一个标准的应用程序中。只不过这个应用程序是随Android系统一起安装进设备的，并且多数情况下由系统来调用和控制（理论上普通应用程序也可以操作它）。

如果读者有Android设备，并且喜欢DIY软件，相信会注意到系统中有一个名为“android. process.media”的常驻进程。那么android.process.media具有什么样的功能，为什么它需要常驻内存？如图13-37所示。

我们从Android源码中可以找到答案。这个进程是下面几个应用的“母体”：

- MediaProvider;
- DownloadProvider;
- DrmProvider。

可见，虽然名称带有“media”，但其实并不仅仅和多媒体有关

联。

接着我们看看MediaProvider在AndroidManifest.xml中的声明：

```
/*AndroidManifest.xml*/
<application android:process="android.process.media"android:label
              android:supportsRtl="true">
<provider android:name="MediaProvider" android:authorities="media
              android:multiprocess="false" android:exported="true
<grant-uri-permission android:pathPrefix="/external/" />
                /*这个权限允许以"/external"开头的path可以临时获取访问权限
<path-permissionandroid:pathPrefix="/external/"
                 android:readPermission="android.permission.READ_
                 android:writePermission="android.permission.WRIT
</provider>
…
```

可见，MediaProvider对访问权限设置了比较严格的要求。

我们知道ContentProvider本质上是对数据库（或者其他存储方式）的管理，从这个角度来说MediaProvider所要做的工作就是创建用于存储各种媒体信息的数据库，并提供更新、查询等操作。那么，它维护了哪些数据库呢？图13-38显示了MediaProvider安装目录下生成的所有数据库。

Android4.1 [emulator-5554]	Online		Android4.1 [4.1.1, debug]
system_process	146		8600
com.android.systemui	215		8601
com.android.phone	245		8603
com.android.launcher	266		8604
com.android.settings	280		8605
android.process.acore	311		8606
com.android.calendar	330		8607
com.android.deskclock	361		8608
com.android.providers.calendar	381		8609
com.android.contacts	396		8610
com.android.mms	430		8611
android.process.media	446		8612
com.android.email	476		8613
com.android.exchange	495		8602
com.android.inputmethod.latin	536		8614

▲图13-37　一个刚启动的Android设备的进程情况

Name	Size	Date	Time	Permissions
com.android.providers.media		2012-09-10	17:15	drwxr-x--x
cache		2012-09-10	17:15	drwxrwx--x
databases		2012-09-10	17:16	drwxrwx--x
external.db	159744	2012-09-10	17:16	-rw-rw----
external.db-shm	32768	2012-09-24	20:12	-rw-------
external.db-wal	461472	2012-09-24	20:12	-rw-------
internal.db	4096	2012-09-10	17:15	-rw-rw----
internal.db-shm	32768	2012-09-24	20:12	-rw-------
internal.db-wal	325512	2012-09-24	20:12	-rw-------

▲图13-38　MediaProvider维护的数据库

可以清楚地看到，数据库分为两类（即internal和external），这和前一小节MediaStore中讲解的VolumeName也是一致的。从理论上来说，程序只需通过internal.db和external.db来分别表示系统内部和外部存储设备即可，为什么还会有external.db-shm这样的数据库存在呢？和很多应用程序一样，数据库的操作也会有很多临时文件。比如当某笔业务失败后，需要回退，此时这些文件就派上用场了。当应用程序成功完成某个操作，或者完全退出后，这些临时的辅助文件是否会被删除则取决于程序本身的设计。有兴趣的读者可以研究下Android中采用的数据库——sqlite。

下面我们看看MediaProvider是如何创建这两个数据库的：

```
  /*packages/providers/mediaprovider/src/com/android/provider
/*这个函数就是创建数据库的地方：  */
private Uri attachVolume(String volume) {
    …
    synchronized (mDatabases) {
        if (mDatabases.get(volume) != null) {
           return Uri.parse("content://media/" + volume); /*如
                                  要再重复创建了。其中mDatabases是一个Ha
                                  DatabaseHelper。如果读者对Android中
                                  楚，建议先看下官方文档，这样对于分析后面
        }
        Context context = getContext();
        DatabaseHelper helper;//用于操作Database的帮助类
        if (INTERNAL_VOLUME.equals(volume)) {
           helper = new DatabaseHelper(context,INTERNAL_DATAB
                                        mObjectRemovedCallback);/*这
                                   此时创建的db名称为INTERNAL_DATABAS
                                   =internal.db。不过数据库并不会马上初
                                   有人使用时才会真正生成，比如getReada
        } else if (EXTERNAL_VOLUME.equals(volume)) {*external
```

```
            if (Environment.isExternalStorageRemovable()) {/*如
               String path = mExternalStoragePaths[0];
               int volumeID = FileUtils.getFatVolumeId(path);/
                …
               String dbName = "external-" + Integer.toHexStri
               helper = new DatabaseHelper(context, dbName, fa
                                           Callback);
               mVolumeId = volumeID;
            } else {/*这种情况用于兼容之前版本中的命名方式，代码省略*/
            …
         } else {
            throw new IllegalArgumentException("There is no vol
          }
          mDatabases.put(volume, helper);//将刚创建的DatabaseHelp
      …
      return Uri.parse("content://media/" + volume);
   }
```

其中，Internal的数据库在MediaProvider执行onCreate()时就会创建，而external.db则需要在外部存储设备存在的情况下才有意义，比前者的判断条件复杂一些。

由此我们知道，MediaProvider为内外存储设备分别建立了两个数据库。不过很明显，每个数据库里还应该有若干数量的Table存在，才能满足前面讲解的各种数据操作需求。比如images，audio，video等类型的文件，其数据属性有较大差异，放在同一张表中来实现并不现实。接下来我们结合MediaProvider所提供的查询过程，来分析其构建出的各种Table的集合：

```
public Cursor query(Uri uri, String[] projectionIn, String select
selectionArgs, String sort) {
        int table = URI_MATCHER.match(uri);//Step1. 匹配Table
        List<String> prependArgs = new ArrayList<String>();
        …
        if (table == VERSION) {//Step2. 如果是查询版本号
            MatrixCursor c = new MatrixCursor(new String[] {"vers
            c.addRow(new Integer[] {getDatabaseVersion(getContext
            return c;
        }
        …
        DatabaseHelper helper = getDatabaseForUri(uri);
         /*通过Uri来选择对应的数据库，只有两个选项——即internal和external
        …
        helper.mNumQueries++; //查询计数值
        SQLiteDatabase db = helper.getReadableDatabase(); /*Step3
```

```
        if (db == null) return null;
        SQLiteQueryBuilder qb = new SQLiteQueryBuilder(); //数据库
        …
        switch (table) { //Step4. 下面的每个case将分别对相应的表进行操
            …
            case AUDIO_MEDIA_ID:
              qb.setTables("audio"); /*设置要查询的表。注意：上面通过U
                                      变量并不是数据库里的表名，大家不要
                qb.appendWhere("_id=?"); /*SQL查询语句的WHERE*/
                prependArgs.add(uri.getPathSegments().get(3));
                break;
            case AUDIO_MEDIA_ID_GENRES_ID:
                qb.setTables("audio_genres");/*可以看到，AUDIO_MEDI
                      AUDIO_MEDIA_ID_GENRES_ID其实是从同一个表中查询，
                qb.appendWhere("_id=?");
                prependArgs.add(uri.getPathSegments().get(5));
                break;
                …//其他类型Table的查询过程都是类似的，我们不再赘述
        }
        Cursor c = qb.query(db, projectionIn, selection,
                combine(prependArgs, selectionArgs), groupBy, nul
                /*利用qb来发出查询请求，它会将上述设置的各种查询条件合成为
        if (c != null) {
            c.setNotificationUri(getContext().getContentResolver(
        }
        return c;
}
```

Step1@query。URI_MATCHER在MediaProvider创建之初就已经通过addURI添加了很多匹配选项。例如，URI_MATCHER.addURI("media", "*/images/media", IMAGES_MEDIA)。

其中第一个参数是Authority，第二个参数是path，它们在后续的匹配操作中都是需要考虑的因素。最后一个参数是本条Uri匹配成功时的返回值。

Step2@query。得到当前数据库的版本号。由此可见，一个ContentProvider的数据来源并不局限于数据库本身。

Step3@query。获取一个可读的Db实例。如果之前这个数据库还没有创建，那么这时就需要真正地去生成这个数据库实例。

Step4@query。这一步执行数据库查询指令。SQlite提供了SQLiteQueryBuilder来帮助用户轻松地构造各种查询参数，因而我们只

需按照要求填写SQLiteQueryBuilder的各项信息即可，最终的数据库查询操作是由SQLiteQueryBuilder.query来完成的。

MediaProvider部分的内容已介绍完，这里小结一下。

- MediaProvider是一个公共的“仓库”：一方面MediaScanner的扫描结果将存储到这里；另一方面上层应用发起的所有查询多媒体文件的业务也在这里展开。
- MediaProvider维护了两个数据库，即internal.db和external.db。
- 每个数据库里又创建了若干Table，来满足各种存储和查询业务需求。
- MediaProvider的Content Uri可以通过MediaStore来查询。

下一小节将讲解多媒体文件管理的核心——MediaScanner。

13.11.3 多媒体文件管理中的“生产者”——MediaScanner

MediaScanner在整个多媒体文件管理中扮演了“生产者”的角色。它源源不断地将“商品”上架或者将“过期商品”下架，以满足“消费者”的需求。

通过之前的了解，我们知道MediaProvider中的数据库分为内部和外部两种。这说明在扫描阶段，MediaScanner也会区分对待这两种存储设备。本小节将围绕以下几个问题点展开：

- MediaScanner的扫描时机；
- MediaScanner的扫描对象；
- MediaScanner的扫描流程。

先来看第一个问题。前面曾经提到过，MediaScanner由一个BroadcastReceiver（MediaScanner Receiver）和一个Service（MediaScannerService）组成，所以它的启动是由广播来触发的。目前MediaScanner可以接收4种类型的广播，如下所示：

```
<receiver android:name="MediaScannerReceiver">
<intent-filter>
<action android:name="android.intent.action.BOOT_COMPLETED" />//开
</intent-filter>
```

```
<intent-filter>
<action android:name="android.intent.action.MEDIA_MOUNTED" />//媒
<data android:scheme="file" />
</intent-filter>
<intent-filter>
<action android:name="android.intent.action.MEDIA_UNMOUNTED" />//
<data android:scheme="file" />
</intent-filter>
<intent-filter>
<action android:name="android.intent.action.MEDIA_SCANNER_SCAN_FI
                                                           //序主动
<data android:scheme="file" />
</intent-filter>
</receiver>
```

剩余的两个问题我们将通过分析上述其中一个广播触发流程（android.intent.action.MEDIA_MOUNTED）来一并解决。

当MediaScannerReceiver接收到MEDIA_MOUNTED的广播后，其首先要对这个广播信息进行初步处理，然后决定是否启动MediaScannerService。源代码如下：

```
      /*packages/providers/mediaprovider/src/com/android/provider
      Receiver.java*/
    public void onReceive(Context context, Intent intent) {
        final String action = intent.getAction();
        final Uri uri = intent.getData();
        if (Intent.ACTION_BOOT_COMPLETED.equals(action)) {//开机时
            scan(context, MediaProvider.INTERNAL_VOLUME);
            scan(context, MediaProvider.EXTERNAL_VOLUME);
        } else {//其他类型广播的处理
            if (uri.getScheme().equals("file")) {//其余广播的scheme
                String path = uri.getPath();
                String externalStoragePath = Environment.getExter
                                             getPath();//得到系统当前设
                if (Intent.ACTION_MEDIA_MOUNTED.equals(action)) {
                    scan(context, MediaProvider.EXTERNAL_VOLUME);
                } else if (Intent.ACTION_MEDIA_SCANNER_SCAN_FILE.
                        path != null && path.startsWith(externalSt
                    scanFile(context, path);//扫描某个文件
                }
            }
        }
    }
```

这个函数中出现了两个分支，即scan()和scanFile()。它们的工作大同小异，其中scan()在启动MediaScannerService的Intent里加入了一个Extra数据。具体如下所示：

```
args.putString("volume", volume);
```

而scanFile()则加入另一名称的Extra信息：

```
args.putString("filepath", path);
```

这样在启动了MediaScannerService后，它会做区分处理（MediaScannerService并不是在启动后就直接处理扫描请求的。它首先会创建一个新线程，然后通过SendMessage()将这些请求发给新线程处理。这样做是遵循了“主线程不做费时操作”的原则）：

```
/*packages/providers/mediaprovider/src/com/android/providers/medi
public void handleMessage(Message msg)
{
    Bundle arguments = (Bundle) msg.obj;
    String filePath = arguments.getString("filepath");
    try {
      if (filePath != null) { // ACTION_MEDIA_SCANNER_SCAN_FILE
      IBinder binder = arguments.getIBinder("listener");
      IMediaScannerListener listener = (binder == null ? null :
      IMediaScannerListener.Stub.asInterface(binder));
      Uri uri = null;
      try {
                uri = scanFile(filePath, arguments.getString("mim
                } catch (Exception e) {
                     Log.e(TAG, "Exception scanning file", e);
                }
                if (listener != null) {
                     listener.scanCompleted(filePath, uri);
                }
                } else {
                     String volume = arguments.getString("volume"
                     String[] directories = null; //需要扫描的目录将

                     if (MediaProvider.INTERNAL_VOLUME.equals(vol
                         directories = new String[] {
                              Environment.getRootDirectory() + "/
                              /*内部存储设备，只扫描media目录*/
                         };
                     }
                     else if (MediaProvider.EXTERNAL_VOLUME.equal
```

```
                        directories = mExternalStoragePaths;
                                /*外部存储设备的扫描目录*/
                    }
                    if (directories != null) {…
                        scan(directories, volume);
                    }
                }
    } catch (Exception e) {
           Log.e(TAG, "Exception in handleMessage", e);
    }
    stopSelf(msg.arg1); //扫描结束后，退出service
}
```

通过上面代码段的分析，可能有的读者会问，系统到底支持几个外部存储设备的扫描呢。也就是说，如果一台嵌入式系统有多个可移除存储设备（比如既支持SD卡，又支持U盘，这种情况很常见），那么能否保证这些存储器的多媒体内容都被扫描到。

我们来总结下系统对几个广播事件的处理过程就明白了，如图13-39所示。

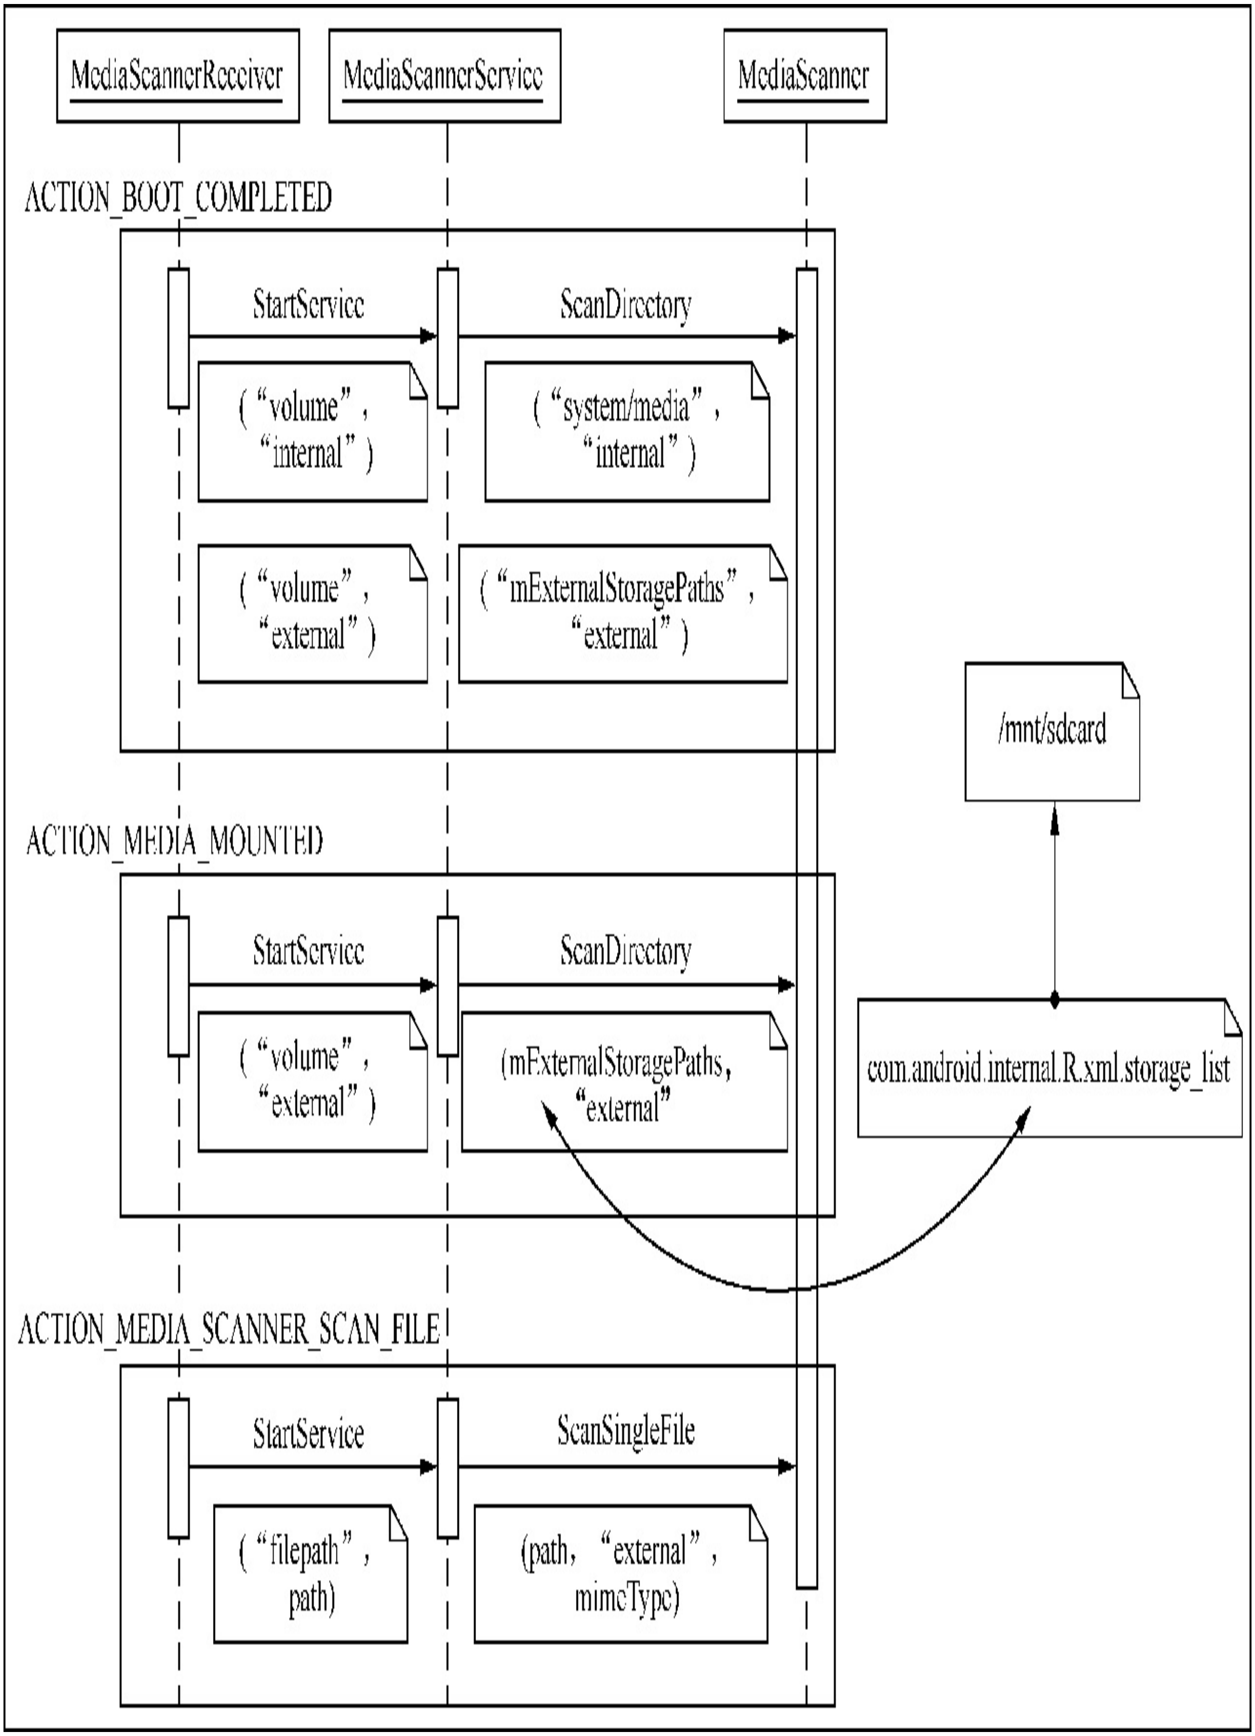
MediaScannerReceiver
MediaScannerService
MediaScanner
ACTION_BOOT_COMPLETED
StartService
ScanDirectory
（“volume”，“internal”）
（“system/media”，“internal”）
（“volume”，“external”）
（“mExternalStoragePaths”，“external”）
/mnt/sdcard
ACTION_MEDIA_MOUNTED
StartService
ScanDirectory
（“volume”，“external”）
(mExternalStoragePaths，“external”
com.android.internal.R.xml.storage_list
ACTION_MEDIA_SCANNER_SCAN_FILE
StartService
ScanSingleFile
（“filepath”，path)
(path，“external”，mimeType)

▲图13-39 MediaScanner对3种广播的处理流程图

- ACTION_BOOT_COMPLETED

扫描内外部存储设备，路径分别为“/system/media”和mExternalStoragePaths指定的目录。

- ACTION_MEDIA_MOUNTED

扫描的是外部存储设备，具体路径是由StorageManager.getVolumeList()→MountService. getVolumeList()取得的，而后者又是通过解析com.android.internal.R.xml.storage_list文件来获取的，当前storage_list中只有“/mnt/sdcard”一个路径。

- ACTION_MEDIA_SCANNER_SCAN_FILE

一般是应用程序产生了一个新的多媒体文件后，发出请求让系统重新扫描，这个新的文件就能被其他用户看到了。

由此可见，当前Android系统中并没有处理多种外部存储设备的情况。如果开发者有这方面的需求，可以尝试修改MediaScannerReceiver的扫描策略。

第3篇 应用原理篇

操作系统对于用户来说最大的价值就体现在应用程序中——无论是Windows、iOS还是Android，生态系统都无一不是建立在相当规模数量的应用程序上。因而如何为APK应用提供高效的开发、调试与发布机制；并针对研发中的常见问题提供统一的解决方案，是保证Android系统“长盛不衰”的法宝。

阅读本篇内容，希望读者已经清楚Android应用程序的开发流程以及常用控件、布局的使用。做到这一点并不难——只要依照Android的SDK向导尝试建立一个“HelloWorld”入门级应用，然后加入一个想实现的功能，如使用MediaPlayer类来完成简易的音乐播放器即可。

第14章 Intent的匹配规则

第15章 APK应用程序的资源适配

第16章 Android字符编码格式

第17章 Android和OpenGL ES

第18章 “系统的UI”SystemUI

第19章 Android常用的工具“小插件”——Widget机制

第20章 Android应用程序的编译和打包

第21章 Android虚拟机

第22章 Android安全机制透析

第14章 Intent的匹配规则

写过Android应用程序的开发者对Intent一定不陌生。从字面来看，Intent是“意愿”“意图”——这个名称很好地表达了Intent设计者的“初衷”。如果说Binder是程序间的“沟通媒介”，那么Intent就是系统判断需要在哪两个进程间建立Binder关联的重要考量因素。

打个比方，“婚介所”（Android）在匹配一对新人（进程）时，假设女方的要求（Intent）是“年龄在30岁以下，有房，有车”，那么“媒人”就需要从一堆资料中找到年纪不超过30并且有房有车的男士。如果恰好有多个目标对象同时满足要求怎么办呢？有两种选择：

- 由系统自动按某种优先级进行比较，如有房有车的，且又长得帅的，那么就可以择优录取；
- 或者把这些资料都列出来，由女生自己来选择。

后一种方式比较民主，因为“萝卜青菜，各有所爱”，我们确实没有办法准确知道每个人的喜好——这也是Android系统采用的解决方法。当系统匹配出有多个目标进程符合Intent的“意愿”时，它会弹出提示框让用户自己选择。

Intent并不是某个组件（如Activity）专用的，它所承载的“意愿”可以来源于多种发起者。也就是说，上面的“婚介所”既可以为女生提供寻找优秀男士的服务，也可以为男生找寻合适的另一半“牵线搭桥”。不管发起方是谁，目标对象又是谁，他们所采用的“意愿”格式都不会发生本质的改变，只不过在条件的填写上有所不同罢了。

14.1 Intent属性

在Android系统的设计中，Intent可以被应用于除ContentProvider外的其他3种组件（即Activity、Service和BroadcastReceiver）。因此，Intent的属性定义一定要有共通性。下面我们来具体看看它有哪些可选属性。

- Component Name

Intent可以被分为两类，即显性（Explicit Intents）和隐性（Implicit Intents）。如果我们在Intent中特别指定了目标方的“Component Name”，比如：“com.example.project.HelloActivity”；同时指定它所在的PackageName，如“com.example.project”，那么系统就会直接将此Intent发往这个特定的应用，而不需要做额外的匹配工作。举个例子，如果女方的择偶要求规定男方的名字就得叫作“某某人”，且带有详细的居住地址（这样才能唯一确定一个人，因为同名的人肯定是存在的），那么婚介所的工作就简单了，直接约见住在这一地址的叫作“某某人”的男生便可。当然这种情况比较少见，因为它降低了女方的可选择性，而且前提是女生事先就已经认识这位男士。如果一个应用程序通过这种方式显性调用另一个应用进程，多半是这两个应用程序同属于一家研发公司，或者是同一进程中的两个组件。

- Category

Category是“种类”的意思，它将Intent从大的方向上进行了区分和归类。如果说上面的Component Name是某人的名字，那么Category就好比国籍。Android系统中已经预设了一些“国家”，我们摘录其中的部分核心元素。另外，由于Intent的所有属性值实际上都只是一串字符，因而是可以自定义的。我们从它的addCategory(String)方法的入参也可以推测到这点，如表14-1所示。

表14-1　系统预设的Category（节选）

Category Name	Description

CATEGORY_BROWSABLE	目标方能解析并正确显示网页链接所指向的内容，如图片、E-mail等
CATEGORY_SAMPLE_CODE	这个应用程序是一个Sample
CATEGORY_TEST	这个应用程序将被当成测试使用
CATEGORY_HOME	这个应用程序是系统启动后的第一个应用，即Launcher
CATEGORY_LAUNCHER	这个应用程序可以通过点击Launcher中的程序图标来启动
CATEGORY_PREFERENCE	这个应用程序是preference panel

- Action

动作。表明要做什么，或者什么事件发生了（常用于广播的情况。比如设备开机时会有系统广播发出，如果应用程序希望实现开机自启动，就可以监听这个广播）。和Category一样，用户也可以自定义一项唯一的Action，如“com.ThinkingInAndroid.action.example”。表14-2是Android系统中预定义的部分常见Action，读者可以参考一下。

表14-2　　系统预设的Action（节选）

Action Name	**Description**
ACTION_CALL	希望启动一个可以拨打电话的Activity

ACTION_EDIT	希望启动一个提供编辑功能的Activity，通常是和其他属性配合使用
ACTION_MAIN	启动的Activity是其应用程序的初始界面
ACTION_SYNC	启动的Activity可以与服务器进行数据同步
ACTION_BATTERY_LOW	从这一项开始到表格末尾的ACTION都属于“事件”通知，它们面向Broadcast组件。 比如ACTION_BATTERY_LOW是当电池电量低时发出的
ACTION_HEADSET_PLUG	当耳机插入或者拔出时发出
ACTION_TIMEZONE_CHANGED	时区变更时发出
ACTION_SCREEN_ON	屏幕开启时发出

- Data

打个比方，如果上面的Action中表明了某人去公安局出入境处“办理签证”的“动作”，那么这里的Data就作为“签证”业务的补充材料——比如这个人的名字、身份证件等。所以，Action理论上是围绕Data

提供的数据来开展业务的。当然也有不需要Data补充信息的情况，如在ACTION_CALL的情况下，电话号码是必须作为Data来传递的；而针对Broadcast（如ACTION_SCREEN_ON）组件的Action，它们本身就蕴含了足够的信息，因而不需要Data的支持。

不同的Action，其对应的Data格式会有所差异，我们在下一小节的匹配过程中再进一步讲解。

- Extras

Extras可以理解为Extra Data，它是对上面Data属性的补充。不过两者在数据的格式上有明显区别。Data采用了类似scheme://uri的表达方式；而Extras则是一种键值对实现。它们在表达不同场景的数据时有各自的优势，使用者应该“具体问题具体分析”。发送方通过一系列putXXX()方法将键值对存入Intent中，然后接收方就可以用相对应的getXXX()来获取到这些Extra数据。这些方法的内部会维护一个Bundle对象来保证进程间数据的准确传输。

- Flags

Flags和Activity中的LaunchMode功能基本相同，它规定了系统如何去启动一个Activity（比如指定即将启动的Activity应该属于哪一个Task）。举个例子，如果一开始Task栈从下往上的顺序是A-B-C，随后C通过带有Flag为FLAG_ACTIVITY_CLEAR_TOP的Intent来启动另一个Activity。如果该Activity在栈中已经存在，比如说是B，那么启动后的Task栈就变成了A-B；否则该Activity直接入栈，而不会先清理栈顶。

14.2　Intent的匹配规则

Intent是和Intent-filter配套使用的。具体而言，Intent-filter是每个组件的属性标签，它们在AndroidManifest.xml声明时就已经“贴上”了。而Intent则是程序运行过程中产生的实时“需求”。系统接收到这些请求后与现有的Intent-filter进行匹配，然后选择最合适的组件元素以响应。

还以前述的“婚介所”为例子，Intent代表了女生的择偶意愿，而Intent-filter则是众男士的属性描述——年龄、长相、收入等。

图14-1描述了广播BroadcastReceiver的匹配流程，其他组件也类似。

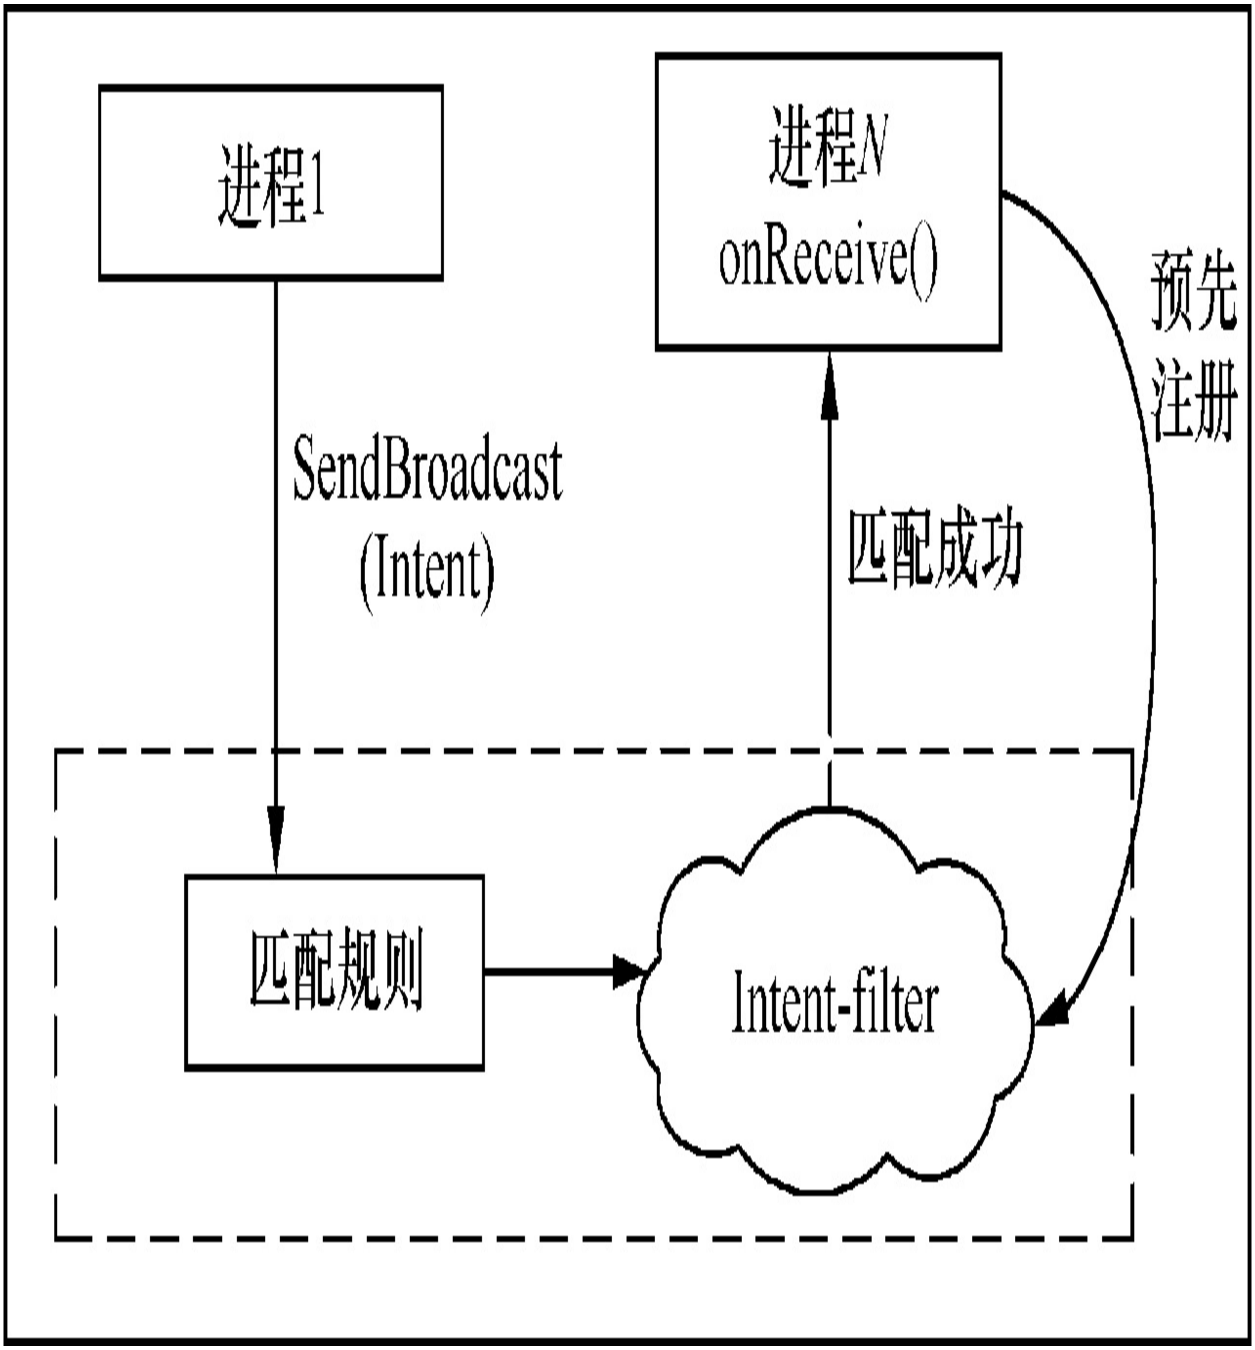

▲图14-1　Broadcast匹配流程图

从图中可以看到，Intent的典型匹配过程包括如下几个步骤。

Intent匹配流程步骤1：组件注册

当应用程序安装到系统中时，Android会通过扫描它的

AndroidManifest文件来得到一系列信息——这其中就包括了它的<intent-filter>；而且系统还会根据组件的不同进行相应的细化归类。比如Activity和Service，它们响应Intent的场合是不同的（前者是startActivity，后者则是startService）。换句话说，当某人调用了startActivity后，显然系统只需在所有Activity中做匹配即可，而不应该再去考虑Service中的Intent-filter。

除了在AndroidManifest中静态注册外，BroadcastReceiver还可以在程序运行过程中进行动态注册。

这两种方式的区别如下：

- 静态注册

所谓静态，即不是在运行过程中执行的。应用程序事先将Intent-filter书写到AndroidManifest文件中。

范例如下：

```
<application android:icon="@drawable/icon" android:label="@string
<activity android:name=".MainActivity"android:label="@string/app_
<intent-filter>
<action android:name="android.intent.action.MAIN" />
<category android:name="android.intent.category.LAUNCHER" />
</intent-filter>
</activity>
<receiver android:name="Receiver1">#receiver组件
     <intent-filter> #用intent-filter来匹配一个感兴趣的广播
          <action android:name="android.intent.action.BOOT_COMPLE
     </intent-filter>
</receiver>
<receiver android:name="Receiver2"> #系统对应用进程注册的filter个数没
     <intent-filter>
          <action android:name="android.intent.action. BATTERY_LO
     </intent-filter>
</receiver>
</application>
```

- 动态注册

动态是指注册操作发生在程序运行过程中。这种注册方式的典型范例如下所示：

```
IntentFilter filter = new IntentFilter("android.intent.action.BOO
DynamicBroadcastReceiver br = new DynamicBroadcastReceiver();
registerReceiver(new DynamicBroadcastReceiver(), filter);//动态注册
…
class DynamicBroadcastReceiver extends BroadcastReceiver//扩展Broa
{
    public void onReceive(Context context, Intent intent) //当匹配
    {
        //Intent是通过sendBroadcast发送出来的
        if(android.intent.action.BOOT_COMPLETED.equals(intent.get
        {…////相应处理
        }
        else
        {…////其他处理
        }
    }
}
```

Intent匹配流程步骤2：发起方主动向系统提供Intent

这一步是在程序运行过程中发生的，此时系统已经掌握了所有组件的<intent-filter>信息。发起方根据自己的需求填写Intent，并按照目标方是Activity，Service还是BroadcastReceiver来调用对应的函数。如下所示：

```
Activity→对应startActivity();
Service →对应startService();
BroadcastReceiver→对应sendBroadcast();
```

应该清楚的是，系统会严格区分对待这些组件分类。所以利用startActivity()是绝对不可能启动Service的——即便Intent和intent-filter能成功匹配。

Intent匹配流程步骤3：系统将Intent和对应组件类型（Activity，Service等）里所有的intent-filter进行匹配，以寻找最佳的结果。

这是整个匹配流程中的核心。前面说过，Intent分为显性和隐性两种。如果是显性的情况就不需要做匹配了，直接根据Intent中的Component Name来启动目标组件（即便这个组件没有声明任何intent-filter）。所以，下面我们以隐性Intent为例来讲解匹配的规则。

读者在学习的过程中也可以和下一章节的“资源最佳匹配过程”进行比较，以加深理解。总的来说，Intent的最终匹配结果可以是多个，而资源匹配则只会有一个胜出者。

影响Intent匹配规则的只有3个关键因素，即：

- Category；
- Action；
- Data（URI和数据类型都要同时匹配）。

而其余两个属性Extras和Flags则只有在选中的组件运行后才能起作用。和资源匹配不同的是，一个组件可以同时声明多个intent-filter。而在匹配过程中，只要它包含的任何一个filter通过了测试，它就会被选中。如果以“身份”来比喻一个组件，这相当于它可以同时拥有多个国籍（Category），或者承担多份工作（Action，如在中国是教师，在美国是牧师，这是有可能的），以及每份工作所包含的数据（Data）不同。在匹配测试中，系统遵循“子集”的概念。换句话说，Intent中的3个关键因素至少要是该组件所包含的其中一个intent-filter的子集（Data有点特殊，下面有详细解释），才能通过验证，如图14-2所示。

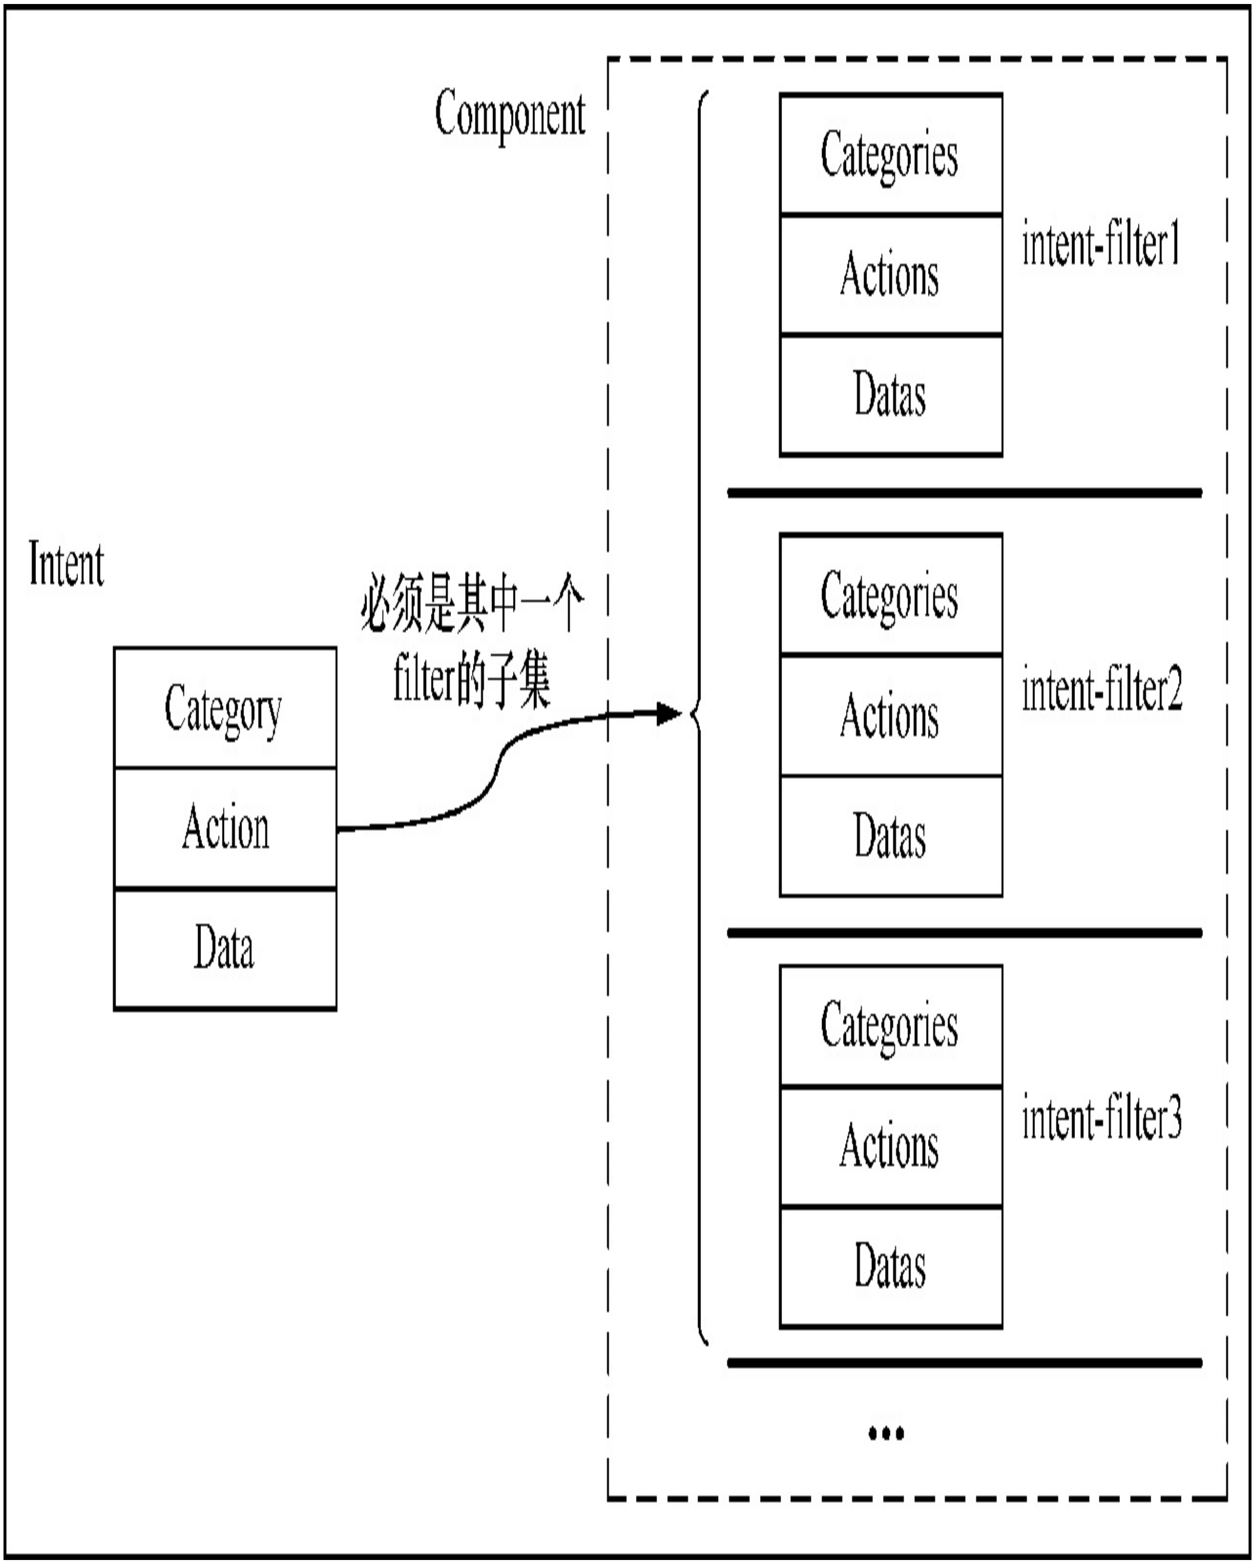

▲图14-2　Intent和Intent-filters

图中有几个地方需要向读者解释一下。

- 每个Component（Activity、Service、BroadcastReceiver）都可以有若干个intent-filter。这和资源匹配不同，因为每种资源只能有一种标签。
- 影响匹配的只有Category、Action和Data，不包括Extras和Flags。
- 每个filter里的上述3种属性都可以不是唯一的（因此我们在图中标注的是复数形式），可以参照下面的例子。
- 匹配时，Intent中的3种属性都需要通过测试。接下来，我们逐个分析各关键因素在匹配时采用的详细规则。

Category测试：

Intent中的Category需要在filter中找到完全匹配的项，才能通过测试。有的读者可能会问：那如果Intent中不指定任何Category，是不是一定能通过检查？理论上确实是这样的。不过Android系统已经预料到这种情况，因而这里有个特殊的地方需要注意——如果Intent中不指定任何Category，系统会自动为其添加一个“android.intent.category.DEFAULT”。这也就是想接收隐性Intent的filter里一般都要添加一个DEFAULT类型category的原因。当然，如果Filter里已经带有“android.intent.action.MAIN”和“android.intent.category.LAU就可以不用再另外书写DEFAULT了，这是一个例外。

Action测试：

Action的匹配相对简单，概括起来只有3点。

- 如果filter没有任何action，那么所有intent都无法通过测试。
- 如果filter中的action不为空，那么intent中不带action的filter可以通过这项属性测试。
- 如果filter中的action不为空，且intent中的action也不为空，那么后者必须是前者的子集才能通过测试。读者可以参见下面的Note Pad例子以帮助理解。

Data测试：

3项属性测试中最复杂的是Data检验，Data的内容通常包括两部分。

- MIME Type

Multipurpose Internet Mail Extensions（MIME）最早是电子邮件协议SMTP（RFC 2046）中所规定的Internet Email的文件格式类型，后来逐渐被运用于其他多种互联网协议（比如HTTP、RTP等）中。它由两部分组成，即主类型（type）和子类型（subtype），中间以“/”分隔。

MIMEType的目的很简单，就是指明某段数据是什么格式类型，以保证程序能正确解析处理。比如电子邮件中的附件，如果不特别说明，接收方客户端就没办法知道它们是图片、文本还是应用程序。这样的结果就是用户找不到合适的途径来对附件进行解析。国际标准中已经预设了很多常见的文件类型，举例如下。

- Application

```
application/javascript  ##Javascript或者ECMAScript类型
application/pdf         ##Portable Document Format
application/zip          ##ZIP文档
```

- Audio

```
audio/mp4               ##mp4音频文件
audio/mpeg              ##MP3或者其他MPEG音频
audio/ogg               ##Ogg Vorbis，Speex等
```

- Video

```
video/mp4               ##MP4视频文件
video/quicktime         ##QuickTime视频
```

video/ogg ##Ogg Theora等视频

- Text

text/html ##Html文件

text/xml ##Xml文件

text/plain ##文本文件

- Image

image/gif ##Gif文件

image/jpeg ##JPEG文件

image/png ##PNG文件

另外，type和subtype中以x-开头的属于非标准格式（未向IANA注册）；而subtype中以vnd开头的则是厂商自定义的（vendor-specific）。

比如：

application/vnd.oasis.opendocument.text ##OpenDocument文本

application/vnd.ms-excel ##Microsoft Excel文件

application/x-latex ##LaTeX文件

audio/x-caf ##Apple公司的CAF音频文件

Android系统中也有不少自定义的类型，在后面的例子中会看到。

- URI

URI（Uniform resource identifier）是某种资源的全球唯一定位标志，因而通常被应用于网络环境中，格式如图14-3所示。

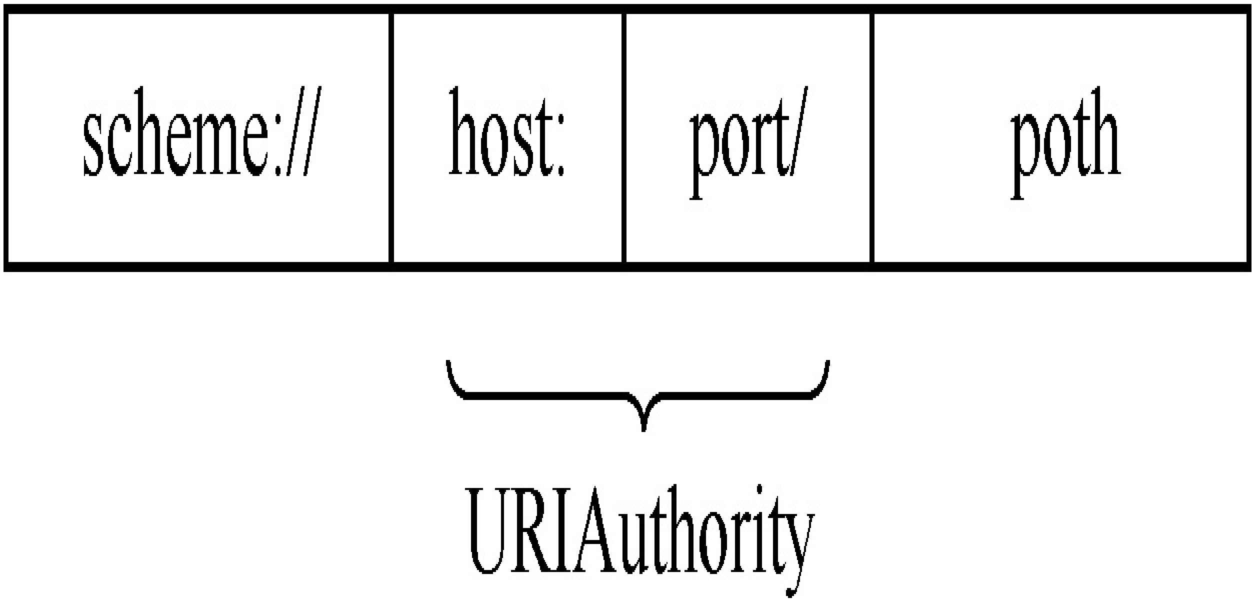

▲图14-3 URI的格式

其中，scheme不仅包括了传统的“http”等网络协议，还有“content”来表示本地ContentProvider所提供的数据。如图所示，“host”是主机的名称，“port”指明通信的端口，它们统称为“Authority”；而且如果host不存在，后面的端口号也会被忽略。最后一部分是文件的路径，它是该资源在host中的具体位置。

虽然我们允许URI中有部分信息缺失的情况，但要特别注意它们之间并不是完全独立的——如果scheme不指定，则authority就没有意义；同样，如果scheme和authority不指定，那么path也没有意义。所有元素组合后构成了一条完整的URI，比如：

```
content://com.google.provider.NotePad/notes
content://com.example.project:200/folder/subfolder/etc
```

了解了Data中的组成元素后，我们再来具体看看它的匹配流程。Data和上面的Category和Action有本质区别。如果说前面的Category和Action遵循的是“intent中属性必须是filter子集”的原则，那么Data则大相径庭——只有filter中存在的那部分属性（比如某filter中只指定了mimeType，那么只匹配mimeType），才需要进行匹配。

根据概率组合，具体有如下4种可能。

（1）Intent中既没有指定数据类型，也没有填写URI。

在这种情况下，只有filter中也同样没有指定数据和URI，才可能通过测试。

（2）Intent中没有指定类型（且无法从URI中推断出），但有URI。

值得一提的是，数据类型有可能从URI中推断出来——如果是就属于第四种情况。前面已经说过，“只有filter中存在的那部分属性，才需要进行匹配”，因而这种情况下filter必须没有指定类型，且Intent中的URI也符合要求，才可能通过测试。

（3）Intent中只指定了类型，没有URI。

这和上面的情况类似。此时如果filter中也没有URI，且Intent中指定的类型符合要求，才能通过测试。

（4）Intent中同时指定了类型（或可以从URI推断出）和URI。

这时类型和URI都必须通过测试。具体来说，以filter中的data为主导，将其中存在的属性逐一与Intent中的data进行比较。不过有一种特殊情况，即filter默认就支持content:和file:的scheme。换句话说，即使它只填写了类型部分，URI中也会有这两个scheme存在。

接下来举一个Android官方文档中的例子以帮助大家加深理解。这个NotePad范例在SDK中可以找到源码，它的intent-filter定义如下所示：

```
/*<sdk>/samples/NotePad/ , AndroidManifest.xml*/
/*为了讲解方便，下面我们给每个filter都标注了序号*/
<manifest xmlns:android=http://schemas.android.com/apk/res/androi
<application android:icon="@drawable/app_notes"android:label="@st
<provider android:name="NotePadProvider"android:authorities="com.
<activity android:name="NotesList" android:label="@string/title_n
 <intent-filter> //NotesList-filter-1
  <action android:name="android.intent.action.MAIN" />
  <category android:name="android.intent.category.LAUNCHER" />
 </intent-filter>
```

```
 <intent-filter>//NotesList-filter-2
  <action android:name="android.intent.action.VIEW" />
  <action android:name="android.intent.action.EDIT" />
  <action android:name="android.intent.action.PICK" />
  <category android:name="android.intent.category.DEFAULT" />
  <data android:mimeType="vnd.android.cursor.dir/vnd.google.note"
 </intent-filter>
 <intent-filter>//NotesList-filter-3
  <action android:name="android.intent.action.GET_CONTENT" />
  <category android:name="android.intent.category.DEFAULT" />
  <data android:mimeType="vnd.android.cursor.item/vnd.google.note
 </intent-filter>
</activity>

<activity android:name="NoteEditor"android:theme="@android:style/
                  android:label="@string/title_note" >
 <intent-filter android:label="@string/resolve_edit"> //NoteEdito
  <action android:name="android.intent.action.VIEW" />
  <action android:name="android.intent.action.EDIT" />
  <action android:name="com.android.notepad.action.EDIT_NOTE" />
  <category android:name="android.intent.category.DEFAULT" />
  <data android:mimeType="vnd.android.cursor.item/vnd.google.note
 </intent-filter>
 <intent-filter> //NoteEditor -filter-2
  <action android:name="android.intent.action.INSERT" />
  <category android:name="android.intent.category.DEFAULT" />
  <data android:mimeType="vnd.android.cursor.dir/vnd.google.note"
 </intent-filter>
</activity>

<activity android:name="TitleEditor" android:label="@string/title
                  android:theme="@android:style/Theme.Dialog">
 <intent-filter android:label="@string/resolve_title"> //TitleEdi
  <action android:name="com.android.notepad.action.EDIT_TITLE" />
  <category android:name="android.intent.category.DEFAULT" />
  <category android:name="android.intent.category.ALTERNATIVE" />
  <category android:name="android.intent.category.SELECTED_ALTERN
  <data android:mimeType="vnd.android.cursor.item/vnd.google.note
 </intent-filter>
</activity>
</application>
</manifest>
```

根据上面的AndroidManifest文件，可以看到NotePad共包含了3种Activity，即NotesList（用于显示已经保存的文章），NoteEditor（用于编辑文章）和TitleEditor（用于编辑文章的标

题）。

下面我们通过列举几个不同的Intent来分析系统的匹配情况。

Intent 1：

```
action: android.intent.action.MAIN
category: android.intent.category.LAUNCHER
```

Category测试：根据子集原则，只有NotesList-filter-1通过了检查。

Action测试：依据上面所分析的Action测试第3点，NotesList-filter-1通过了检查。

Data测试：属于第一种情况，即intent里既没有指定类型，也无URI。而另外，filter也是同样的情况，因此根据“只有filter里有的那部分属性才需要检查”的原则，NotesList-filter-1最终通过了匹配。这个Intent1将对应NoteList。

Intent2：

```
action: android.intent.action.VIEW
data: content://com.google.provider.NotePad/notes
```

Category测试：Intent中没有指定Category，系统会自动为其加上DEFAULT值。因为所有filter都写上了这个默认值，因而全部通过测试。

Action测试：只有NotesList-filter-2和NoteEditor-filter-1通过测试。

Data测试：表面上属于第二种情况，即只指定了URI而没有类型。但实际上从这个例子中的content可以推断出type，因而属于第四种情况。推断出的类型为"vnd.android.cursor.dir/vnd.google.note"（可以参见下一小节对推断过程的源码解析），因而最终通过测试的是NotesList-filter-2。

Intent3：

```
action: android.intent.action.GET_CONTENT
data type: vnd.android.cursor.item/vnd.google.note
```

Category测试：同Intent2。

Action测试：只有NotesList-filter-3通过测试。

Data测试：只有Type，而没有URI，属于第三种情况。因为NotesList-filter-3也是同样的情况，而且它们的类型也是匹配的，所以最终通过测试。

Intent4：

```
action: android.intent.action.INSERT
data: content://com.google.provider.NotePad/notes
```

Category测试：同Intent2，由此可见intent-filter中加上DEFAULT还是非常必要的。

Action测试：只有NotesEditor-filter-2符合要求。

Data测试：同Intent2。

Intent5：

```
action: com.android.notepad.action.EDIT_TITLE
data: content://com.google.provider.NotePad/notes/ID
```

Category测试：同Intent2。

Action测试：只有TitleEditor-filter-1符合要求。

Data测试：同样可以推断出类型，即"vnd.android.cursor.item/vnd.google.note"，因而上面的TitleEditor-filter-1最终通过测试。

14.3 Intent匹配源码简析

本节将对Intent匹配过程所涉及的核心源码进行简单的分析。

我们以startActivity为例，程序调用流程如图14-4所示。

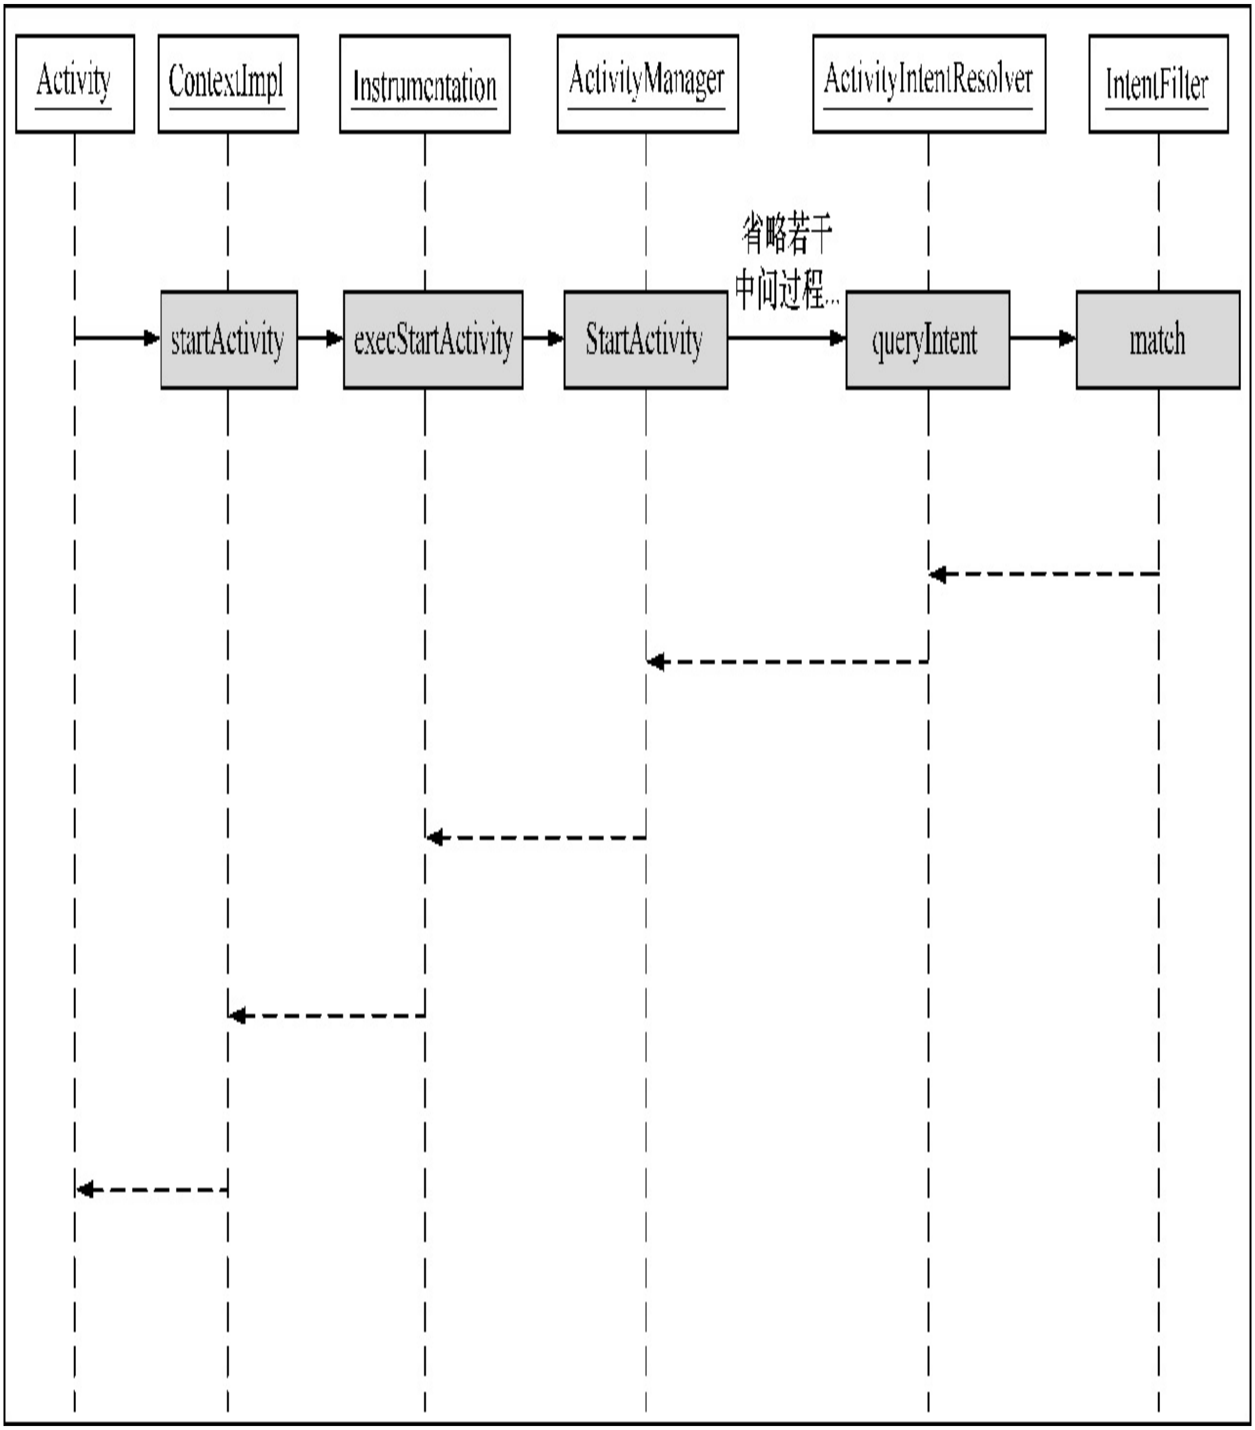

▲图14-4　从startActivity中看Intent匹配过程

所以，最终执行匹配的是IntentFilter中的match()函数。不过在这之前已经涉及很多快速匹配算法优化的地方，若读者有兴趣可以自行阅读中间过程的代码。我们这里着重分析一下最后的这个匹配函数：

```
/*frameworks/base/core/java/android/content/IntentFilter.java*/
public final int match(String action, String type, String scheme,
                       Set<String> categories, String logTag) {
       if (action != null && !matchAction(action)) {/*首先匹配Actio
                                         matchAction ()要求action不为空并且fi
                                         中的action，否则返回false表示匹配不成
            return NO_MATCH_ACTION; /*Action测试失败，没有必要再往下匹
        }
        int dataMatch = matchData(type, scheme, data); /*紧接着进行
        if (dataMatch < 0) {…
            return dataMatch;
        }
        String categoryMismatch = matchCategories(categories); /*
                                                     轮测试不一样的地方是，它
        …
        return dataMatch; /*到这里说明3个测试都通过了*/
    }
```

整个match函数的处理流程和前面的描述一致，即分别调用matchAction，matchData和matchCategories来执行3种检验测试。在match过程中只要有一轮失败，函数就会直接返回错误。

下面专门分析match中最复杂的Data匹配过程：

```
  public final int matchData(String type, String scheme, Uri data
      final ArrayList&lt;String> types = mDataTypes;
      final ArrayList&lt;String> schemes = mDataSchemes;
      final ArrayList&lt;AuthorityEntry> authorities = mDataAutho
      final ArrayList&lt;PatternMatcher> paths = mDataPaths;

      int match = MATCH_CATEGORY_EMPTY;
      if (types == null && schemes == null) {/*Filter的type和URI都
         intent都要为空才能匹配成功。注意复数形式的是filter的属性，单数的为
          return ((type == null && data == null)?
                  (MATCH_CATEGORY_EMPTY+MATCH_ADJUSTMENT_NORMAL)
      }
      if (schemes != null) {/*Filter中的scheme不为空。做这样子判断的目
                                在，后面的authority也就没有意义了*/
          if (schemes.contains(scheme != null ? scheme : "")) {
              match = MATCH_CATEGORY_SCHEME;
          } else {
              return NO_MATCH_DATA;
          }
          if (authorities != null) {//authority不为空
              int authMatch = matchDataAuthority(data); /*匹配Auth
              if (authMatch >= 0) {/*只有在匹配了Authority以后，下面的
```

```
                if (paths == null) {
                    match = authMatch;
                } else if (hasDataPath(data.getPath())) {
                    match = MATCH_CATEGORY_PATH;
                } else {
                    return NO_MATCH_DATA;
                }
            } else {
                return NO_MATCH_DATA;
            }
        }
    } else {/*这就是我们在上一小节的data测试中提到的一种特殊情况，即系统
            和file两种scheme*/
        if (scheme != null && !"".equals(scheme) && !"content".
             && !"file".equals (scheme)) {
            return NO_MATCH_DATA;
        }
    }
    if (types != null) {/*匹配类型，过程和上面URI是类似的*/
        if (findMimeType(type)) {
            match = MATCH_CATEGORY_TYPE;
        } else {
            return NO_MATCH_TYPE;
        }
    } else {
        if (type != null) {
            return NO_MATCH_TYPE;
        }
    }
    return match + MATCH_ADJUSTMENT_NORMAL;
}
```

在前一节中，我们提到当Intent中只包含URI时，是有可能推断出Type的。那么这个过程是在什么时候做的，为什么NotePad中的“content://com.google.provider.NotePad/notes”最终可以得出Type=“vnd.android.cursor.dir/vnd.google.note”？

实际上对Type的推断在startActivity起始就执行了，具体而言是在execStartActivity中。源码如下：

```
/*frameworks/base/core/java/android/app/Instrumentation.java*
public ActivityResult execStartActivity(Context who, IBinder
      token, Activity target,Intent intent, int requestCode,
   …
   try {…
       int result = ActivityManagerNative.getDefault()
```

```
            .startActivity(whoThread, intent,intent.resolveType
            Resolver()), token, target != null ? target.mEmbedd
            0, null, null, options);
        checkStartActivityResult(result, intent);
    } catch (RemoteException e) {
    }
    return null;
}
```

上述代码段就是应用进程把startActivity请求投递给AMS的地方，其中的重点在于函数将调用的resolveTypeIfNeeded——通过函数名也可以看出，它负责从Intent中解析出相应的类型。下面我们对这个函数做进一步分析：

```
 /*frameworks/base/core/java/android/content/Intent.java*/
public String resolveTypeIfNeeded(ContentResolver resolver) {
    if (mComponent != null) {
        return mType; /*如果已经指定了Component Name，那就没必要再
    }
    return resolveType(resolver);
}
```

函数resolveTypeIfNeeded先判断ComponentName是否为空，是就直接返回结果，否则继续调用如下方法：

```
public String resolveType(ContentResolver resolver) {
    if (mType != null) {
        return mType; //已经指定了类型，当然不需要再从URI中推断了
    }
    if (mData != null) {
        if ("content".equals(mData.getScheme())) {/*URI中的sch
                                推断出类型。言下之意，像“http”这种网络协
            return resolver.getType(mData); /*利用ContentResol
        }
    }
    return null;
}
```

由此可见，最终的类型推断是由ContentResolver来完成的。即：

```
 /*frameworks/base/core/java/android/content/ContentResolver.
 public final String getType(Uri url) {
    IContentProvider provider = acquireExistingProvider(url);
                     ContentProvider来完成解析。这给了我们一个提示
                     Provider自己来完成的，而不是系统统一处理的*/
```

```
        if (provider != null) {//provider存在，直接由它完成解析
            try {
                return provider.getType(url);
            } catch (RemoteException e) {
               …//异常处理
            }
        }
        if (!SCHEME_CONTENT.equals(url.getScheme())) {//又判断了一次
           return null;
        }
        try {
           String type = ActivityManagerNative.getDefault().getPr
           return type;
        } …
}
```

如果已经有现成的Provider，那么直接由它来解析类型；如果没有可用的Provider，那么就要先动用AMS来找到相对应的Provider。这和startActivity中利用Intent来找到Activity类似——这里是通过URI来匹配Content Provider。因为Intent中的URI是“content://com.google.provider. NotePad/notes”，Authority是com.google.provider.NotePad，所以最终会匹配到NotePad这个Provider。

所以getType的核心步骤有两个。

（1）根据URI在AMS中找到对应的Content Provider，在这个例子中也就是NotePadProvider。

（2）根据provider中的getType()函数来解析类型。

原来绕了一圈，类型的解析还是由应用程序本身来完成的。这样的设计是合理的，因为它让应用程序有机会来扩展Type的解析能力。因而可以肯定的是，每个provider都必须实现getType()方法；并且这个接口还应该是抽象的，验证如下：

```
public abstract class ContentProvider implements ComponentCallbac
     …
     public abstract String getType(Uri uri); //确实是抽象接口
     …
}
```

最后来看看NotePadProvider是如何解析类型的。这也是分析Android源码一个有趣的现象，很多时候答案就在眼前：

```
@Override
public String getType(Uri uri) {
       switch (sUriMatcher.match(uri)) {
           case NOTES:
           case LIVE_FOLDER_NOTES:
               return NotePad.Notes.CONTENT_TYPE;
          case NOTE_ID:
               return NotePad.Notes.CONTENT_ITEM_TYPE;
           default:
               throw new IllegalArgumentException("Unknown URI "
       }
   }
```

UriMatcher一共添加了3种模式，当uri="content://com.google.provider.NotePad/notes"时，匹配的类型是CONTENT_TYPE ="vnd.android.cursor.dir/vnd.google.note"。根据之前对MIME类型的讲解，vnd表示用户自定义的类型。

当uri="content://com.google.provider.NotePad/notes/ID"时，匹配的类型是：

CONTENT_ITEM_TYPE="vnd.android.cursor.item/vnd.google.note"。

Intent的匹配过程还有很多其他细节，有兴趣的读者可以自行深入阅读代码以加深理解。

第15章 APK应用程序的资源适配

我们在本书其他章节中曾经提过，Android相比于iOS有一个非常让开发者头痛的问题，即市面上Android设备种类繁多、硬件配置五花八门。特别是层出不穷的屏幕分辨率和尺寸，往往对一款应用程序的UI界面有非常大的影响——应用程序在屏幕A上可以完美显示，而在屏幕B上则可能是一团糟。鉴于此，应用开发商往往需要同时适配多达上百款主流设备才敢将产品投入市场，这无疑加大了研发的成本和时间。

作为开源工程，Android无法像iOS一样从本质上去规避这种情况。因此，如何尽可能减小它所带来的影响就成了开发人员首先考虑的问题。这也是本章的目的——我们将从适配一款设备所要做的主要工作入手，结合Android系统提供的通用适配方案和准则，来学习如何在项目开发初期就将这些“烦人”的问题掌握在可控范围内。

我们先从理论层面来分析适配的过程，如图15-1所示。

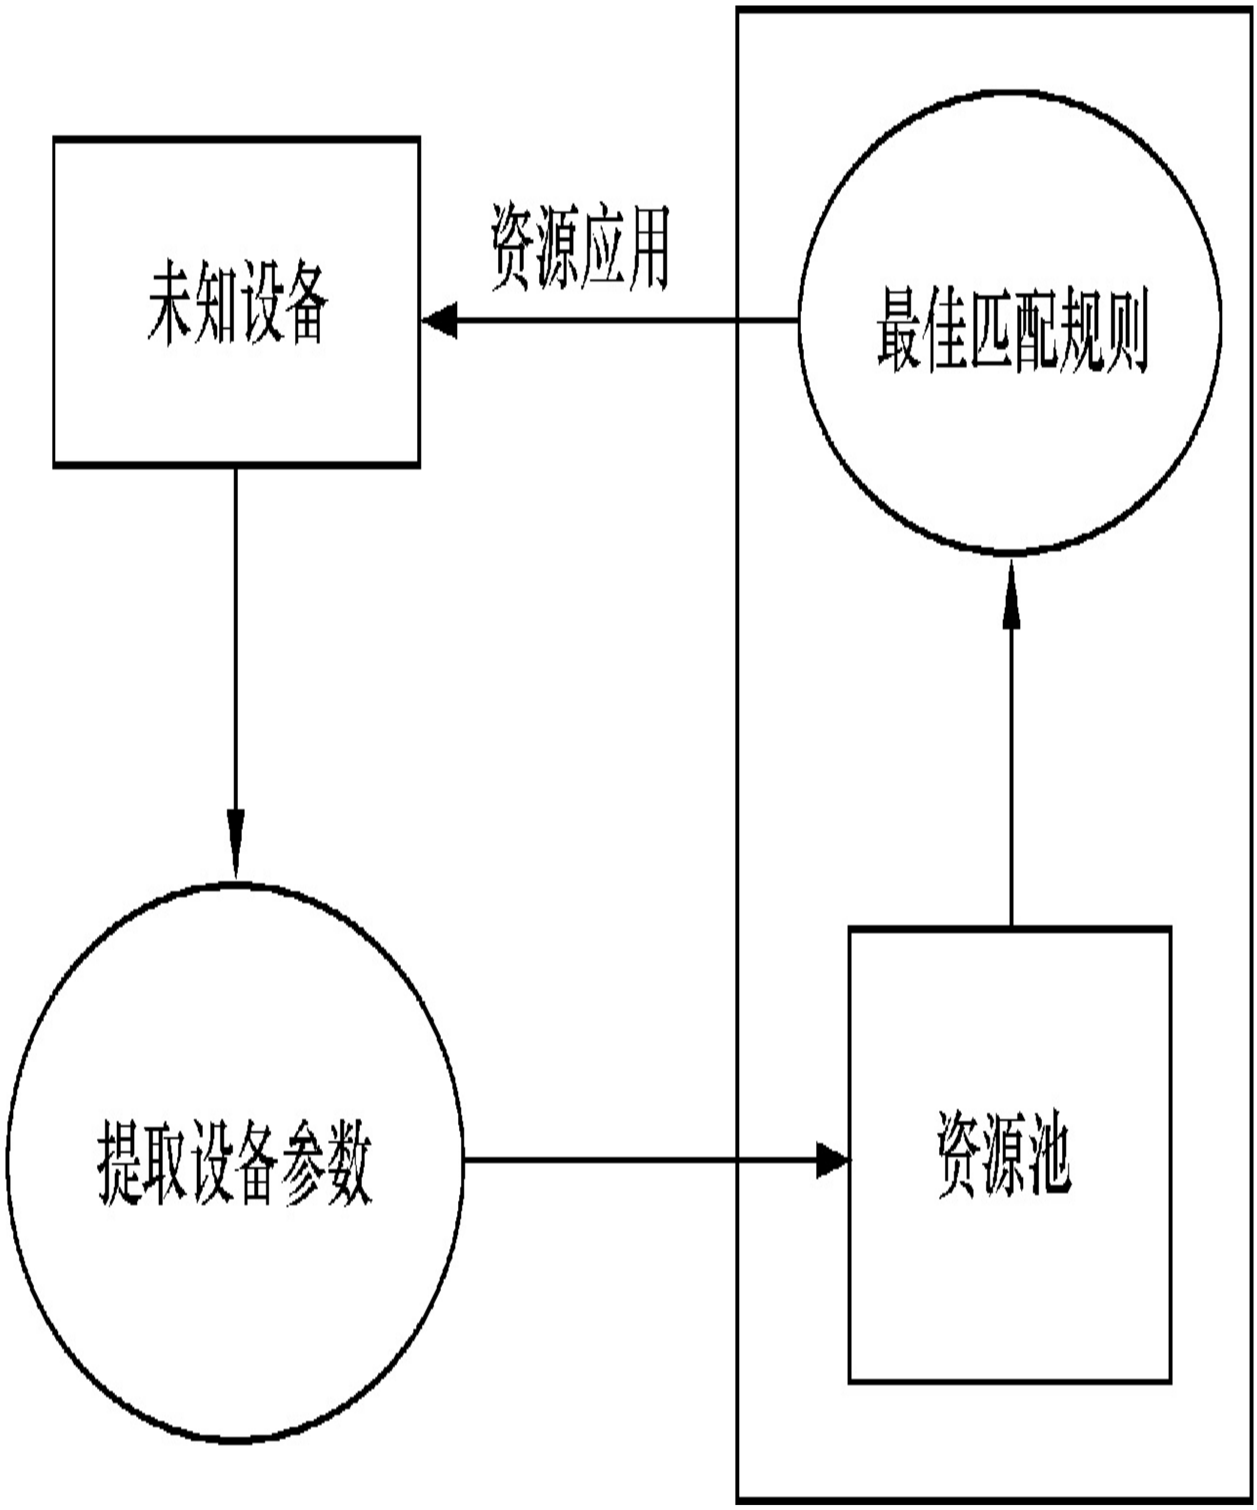

▲图15-1　设备资源适配的通用流程图

- 未知设备

对于发布后的应用程序而言，它将运行于什么配置的硬件设备上是一个未知数。比如一个APK闹钟小工具，不但手机用户可以下载使用，平板电脑用户也同样可以去下载使用。

- 提取设备参数

对于不同的设备而言，它们的硬件和软件参数都可能不一样。例如平板电脑相对于手机通常屏幕都会大一些，而且是横屏；即便是同一款手机，也可能在系统软件版本上存在差异。这些参数都会对资源池的最佳匹配产生影响。我们接下来将总结出和资源匹配相关联的所有设备属性参数。

- 资源池

资源池是对一个应用程序所能提供的“可选资源”的形象称谓。通过“最佳资源匹配”，应用程序可以为当前设备遴选出最合适的资源。

- 最佳匹配规则

这是整个匹配流程的核心，也是最终仲裁者。从应用程序资源池中寻找到最佳匹配的资源，并不是件容易的事。我们将在本章后续小节对Android目前采用的匹配算法进行详细分析。

15.1　资源类型

APK应用程序发布以后——比如通过Android Market（2012年3月7日起更名为Google Play Store）这样的开放平台来提供下载，我们预先没有办法知晓下载者将会把这个应用程序安装在什么样的Android机器上。所以为了达到最佳的适配效果，一方面，开发者需要提供尽可能多的可选资源；另一方面，Android系统本身也会根据设备的配置来对应用程序做运行时的优化。比如适当地拉缩图片以更好地适应屏幕，或者选择合适的layout来搭配横屏、竖屏，以及根据系统的配置来决定应用程序的显示语言等。

如果把Android系统比作舞蹈编排者，那么它如何保证“舞者”的正常演出呢？首先它需要为表演者提供舞步指导，这样才可以要求他们展示一场精彩的表演；反之，如果在没有弄清楚整支舞蹈动作编排的情况下就仓促上阵，很可能会出现各种意想不到的窘相。

本小节我们将解释Android系统包含了哪些应用程序资源以及内部又是如何处理这些资源的。

原生态Android工程包含的资源（resource）类型比较多，它们都统一放置在程序源码的res/目录下。每种资源还会建立自己的子目录——因而大部分资源的类型从它们的目录名称上就可以知晓。比如drawable表示图像文件，layout表示布局文件，anim表示动画实现等。这些名称都是固定的，不允许更改，完整的列表如表15-1所示。

表15-1　Android支持的资源类型

类　　型	存放位置		访问方式	说　　明
动画资源（Animation Resources）	Tween动画	res/anim/	Java中：R.anim.filename XML中：@[package:]anim/filename	预先定义动画实现
	Frame动画	res/drawable/	Java中：R.drawable.filename XML中：@[package:]drawable.filename	
				定义了各

状态颜色资源（Color State List Resource）	res/color/	Java中： R.color.filename XML中： @[package:]color/filename	配色方案并可以根程序的V状态自动择切换颜
图形资源（Drawable Resources）	res/drawable/	Java中: R.drawable.filename XML中: @[package:]drawable/filename	各种图像件
布局资源（Layout Resource）	res/layout	Java中： R.layout.filename XML中： @[package:]layout/filename	布局文件
菜单资源（Menu Resource）	res/menu	Java中： R.menu.filename XML中： @[package:]menu.filename	菜单资源
字符串资源（String Resources）	res/values	Java中： R.string.string_name, R.array.string_array_name, R.plurals.plural_name XML中： @string/string_name等	定义字符和字符串组等
样式资源（Style Resource）	res/values	Java中： R.style.stylename XML中： @[package:]style/style_name	一般用于义UI外观
原始资源（Raw Resource）	res/raw	Java中： R.raw.filename 可以使用Resources.openRaw Resource函数打开此类资源	存放原始式的资源如音频文件。 也可以将类文件存在assets/下，这时

			源不会被 配ID值， 以通过 AssetMa 来访问
其他资源	res/values/	Java中： R.bool.bool_name, R.integer.integer_name, R.color.color_name等 XML中： @[package:]color/color_name 等	用于定义 种变量数 值，如整 形、布尔 型、尺寸

15.1.1 状态颜色资源

之所以称为“状态颜色”（Color State），是因为我们可以为某个View对象的不同状态分别配置特定的颜色。如果只是为了单纯地说明某个颜色的属性，请参照上表中的“其他资源”。

状态颜色的文件结构由一个<selector>，内嵌若干<item>而成。每个<item>描述了一个View状态与某种颜色的对应值：

```
<?xml version="1.0" encoding="utf-8"?>
<selector xmlns:android="http://schemas.android.com/apk/res/andro
    <item
     …
    />
    …
</selector>
```

其中，<item>的声明语法如下：

```
<item
     android:color="hex_color"
     andoird:[VIEW_STATE]=["true" | "false"]
     andoird:[VIEW_STATE]=["true" | "false"]
     …
/>
```

需要格外注意的是，系统只会简单地选择第一个符合要求的

<item>，而不是从众多<item>中选择一个最合适的。另外，即便第一个<item>里不包含任何状态信息，它也会每次都被选中。因此，我们在编写时一定要把默认的值放在最后面。

android:color以“#”开头，可是以下4种表达形式之一：

- #AARRGGBB;
- #RRGGBB;
- #ARGB;
- #RGB。

目前可选的VIEW_STATE有以下几种类型。

- android:state_pressed（被按下状态）。
- android:state_focused（已获取焦点状态）。
- android:state_selected（被选中状态，如一个tab被打开时）。
- android:state_checkable（指一个View是可勾选的）。
- android:state_checked（View已被勾选）。
- android:state_enabled（处于使能状态，即这个view可以接收触摸/点击等事件）。
- android:state_window_focused（应用程序的窗口获得了焦点）。

15.1.2　图形资源

图形资源（Drawable Resources）的定义比较抽象，指的是所有可以被显示到屏幕上的图像，因此包含的类型比较多。下面我们对其中一些核心类型进行解释。

- Bitmap

位图文件，常见的格式有.png、.jpg和.gif

- Clip

这个概念被广泛应用在图形图像处理中，字面意思是图像被剪切、裁剪。这里表达的是一个图形随着状态值（0～10000）的变化而处于不

同的被裁剪状态。比如，一个进度条视图会根据进度的百分比大小而变化。

- Inset

这种类型的图像资源用于插入另一图像中，而且插入位置可以设置。比如一个视图需要一张比其外边框小的背景图，就可以使用Inset。

- Level List

和颜色状态资源类似，Level List管理的是一组图像资源，每个图像又有相应的等级范围。当我们利用setLevel()或者setImageLevel()函数传入所希望的等级值时，系统会选择一个符合要求的图像。

- Layer List

层叠式的图像资源。它也是一组图像资源的集合。和Level List不同的是这些图像会被全部显示，而且绘制的顺序是它们在列表中的声明顺序。也就是说，列表中的最后一个元素会被显示在最上面。Layer List通常可以用来产生层叠效果。

- Nine-patch

Android自定义的一种PNG格式的图像资源。它让图像在拉伸时按照一定的规则进行（即只有指定的“拉伸区域”会被拉伸），而不是传统的整图拉伸。这样做可以有效避免图像因拉伸而产生变形。

- Scale

和Clip Drawable在用法上类似，用于定义一种尺寸大小随等级变化而改变的图形。

- Shape

用于特定形状的定义，如长方形、椭圆形、环形等；并能设置其厚度、圆角、填充、线条等。其一般的语法如下：

```
<?xml version="1.0" encoding="utf-8"?>
<shape xmlns:android="http://schemas.android.com/apk/res/android"
  android:shape=["rectangle" | "oval" | "line" | "ring"] >
 <corners…/>
 <gradient…/>
 <padding…/>
 <size…/>
 <solid…/>
 <stroke…/>
</shape>
```

- State List

这是我们在应用程序开发中最常用的一种资源，描述了视图在不同状态下的变化。它和颜色状态资源在使用及语法上基本一致，只不过一个体现了颜色值的变化，而另一个则通常是背景图的改变。

其格式如下：

```
<?xml version="1.0" encoding="utf-8"?>
<selector xmlns:android="http://schemas.android.com/apk/res/andro
android:constantSize=["true" | "false"]
android:dither=["true" | "false"]
android:variablePadding=["true" | "false"] >
 <item
  android:drawable="@[package:]drawable/drawable_resource"
  android:[VIEW_STATE]=["true" | "false"]
 />
</selector>
```

对于在颜色状态表中已经讲解过的VIEW_STATE，这里不再赘述。以下是此资源新增的两种状态：

① state_hovered（光标悬浮在上面的状态）；

② state_activated（视图对象被持久选择的状态）。

- Transition

这种类型的资源包含最多两个图形，并实现了它们之间的互相切换——如果需要进行前向切换，就使用startTransition()函数；反之，可以使用reverseTransition()函数。

15.1.3　布局资源

布局文件定义了UI界面的框架，并且详细描述了每个View对象的属性和Layout（大小、位置）。

一般格式如下：

```
<?xml version="1.0" encoding="utf-8"?>
<ViewGroup xmlns:android="http://schemas.android.com/apk/res/andr
android:id="@[+][package:]id/resource_name"
android:layout_height=["dimension" | "fill_parent" | "wrap_conten
android:layout_width=["dimension" | "fill_parent" | "wrap_content
    [ViewGroup-specific attributes] >
 <View
  android:id="@[+][package:]id/resource_name"
  android:layout_height=["dimension" | "fill_parent" | "wrap_cont
  android:layout_width=["dimension" | "fill_parent" | "wrap_conte
        [View-specific attributes] >
  <requestFocus/>
 </View>
 <ViewGroup>
  <View />
 </ViewGroup>
 <include layout="@layout/layout_resource"/>
</ViewGroup>
```

- 最外围的元素可以是ViewGroup、View或者merge，同时有且只能有一个顶层元素。
- 顶层元素下面可以包含若干其他元素，如ViewGroup、View等。每个View对象会声明各自的属性。
- 可以通过include来引用其他的布局文件，这样可以把一个非常大的布局分而治之，便于书写和阅读。
- ViewGroup既可以是系统预先提供的RelativeLayout、LinearLayout、FrameLayout等组件，也可以是用户自定义的扩展组件。

15.1.4　菜单资源

菜单资源使我们可以方便地定义出各种Menu选项，包括Options，Context和submenu。它的格式比较简单，如下：

```
<?xml version="1.0" encoding="utf-8"?>
```

```
<menu xmlns:android="http://schemas.android.com/apk/res/android">
     <item…/>
     <group android:id="@[+][package:]id/resource name"
          android:checkableBehavior=["none" | "all" | "single"]
          android:visible=["true" | "false"]android:enabled=["tru
          android:menuCategory=["container" | "system" | "seconda
          android:orderInCategory="integer" >
          <item… />
          …
     </group>
     <item>
          <menu>
          <item />
          </menu>
     </item>
</menu>
```

- 每一个item代表一个菜单选项，可以设置它的id值、标题及点击后的响应函数等；
- 一个菜单的group是指属性相同的一组item；
- 菜单内部还可以嵌套子菜单。

15.1.5 字符串资源

我们知道，在编写Android应用程序源码时，不允许对某个文本属性直接赋予一串字符——这是出于字符串国际化和规范化的考虑。正确的做法是先定义一个字符串资源，并根据不同的地区语言进行赋值。字符串资源分为3类，分别是普通字符串、字符串数组以及数量字符串（Quantity Strings）。

1．普通字符串

这是字符串中最常用的格式，用于定义一个简单的字符串资源：

```
<?xml version="1.0" encoding="utf-8"?>
<resources>
     <stringname="string_name">text_string</string>
</resources>
```

值得一提的是，Android系统目前已经可以支持一些简单的字符串格式的自定义。

- 利用format格式

我们在程序中经常会用到String.format(String format, Object... args)来对字符串进行格式化。在字符串资源的定义中，也可以使用类似的方法来达到目标。

比如我们可以定义如下字符串：

```
<string name="Test_Format_String"> Hi, %1$s, your waiting number
</string>
```

这样在编写源码时，使用如下语句就可以完成字符串的格式化：

```
String.format(res.getString (R.string. Test_Format_String), name,
```

- 利用简单的HTML MARKUP语法

目前支持的元素只有3种，即：

- <b>用于加粗显示；
- <i>用于斜体显示；
- <u>用于加入下画线。

2. 字符串数组

字符串数组的格式如下：

```
<?xml version="1.0" encoding="utf-8"?>
<resources>
     <string-arrayname="string_array_name">
          <item>text_string</item>
          …
     </string-array>
</resources>
```

当程序访问这一资源时，可以通过数组名将所有的字符串元素一次性提取出来。

3. 数量字符串

数量字符串听起来有点拗口，它能根据传入数量值的不同而对字符串做相应调整。格式如下：

```
<?xml version="1.0" encoding="utf-8"?>
<resources>
     <pluralsname="plural_name">
          <itemquantity=["zero" | "one" | "two" | "few" | "many"
               text_string
          </item>
     </plurals>
</resources>
```

这样，我们就可以通过如下接口来获取所需的字符串：

```
public String getQuantityString (int id, int quantity)
```

需要注意的是，“zero”“one”这些词并不代表传统意义上的数值0、1，而是体现了字符串中的元素（如上述的Song）在复数语法上的区分。比如在英语中，0或者2的复数形式都是一样的，它们只和1不同（zero books、one book、two books）。

15.1.6　样式资源

样式资源相当于将常用的UI外观保存成“模板”——这样当下次需要使用同一种样式时，就可以直接调用，而不是重写一遍。

格式如下：

```
<?xml version="1.0" encoding="utf-8"?>
<resources>
     <stylename="style_name"parent="@[package:]style/style_to_inh
          <itemname="[package:]style_property_name">style_value</
     </style>
</resources>
```

- 一种样式可以继承自其他样式——用parent属性表示。
- 可以定义多个item来表示不同的样式属性，如android:textColor，android:textSize等。

如果我们只是需要把样式应用于某个View视图，可以通过View的Style属性来设置。而如果样式需要被应用于整个Activity甚至

Application，可以设置它的android:theme属性——这时我们又可以称为“主题样式”。

15.1.7　其他资源

除了前面几个小节介绍的资源外，Android系统还包含了一些特殊的资源。它们有点类似于变量值的定义，比如：

- Bool；
- Color；
- Diemension；
- ID；
- Integer；
- Integer Array；
- Typed Array。

这些资源在格式的定义和使用上都类似，因而我们只选取Color进行讲解。

和前面颜色状态资源中的描述一样，一种特定的颜色可以“#”开头，并通过#RGB、#ARGB等4种格式来赋值。

语法如下：

```
<?xml version="1.0" encoding="utf-8"?>
<resources>
     <colorname="color_name">hex_color</color>
</resources>
```

15.1.8　属性资源

不论是哪种资源，都是由“属性”来描述的，只不过不同的资源类别拥有的“属性”值有一定区别。Android系统已经为我们预定义了不少常用的属性，可统一以“android”+“:”+[属性名]的方式访问，如android:id，android:visible等。

本小节我们将讲解两方面的内容：

- Android预定义的属性；
- 如何添加自己的属性。

所有framework相关的资源都在源码工程中的frameworks/base/core/res/res/目录下，而关于属性的定义则放在attrs.xml文件中。可以看到，这个文件以<resource>作为外围标签，其余部分则由一系列的<declare-styleable>以及<attr>标签组成。比如：

```
<declare-styleable name="Theme">
          <!-- Default color of foreground imagery. -->
<attr name="colorForeground" format="color" />
<!-- Default color of foreground imagery on an inverted backgroun
<attr name="colorForegroundInverse" format="color" />
<!-- Color that matches (as closely as possible) the window backg
<attr name="colorBackground" format="color" />
     …
</declare-styleable>
```

以及：

```
<resources>
<attr name="textIsSelectable" format="boolean" />
<attr name="gravity">
<flag name="top" value="0x30" />
<flag name="bottom" value="0x50" />
<flag name="left" value="0x03" />
<flag name="right" value="0x05" />
<flag name="center_vertical" value="0x10" />
<flag name="fill_vertical" value="0x70" />
<flag name="center_horizontal" value="0x01" />
<flag name="fill_horizontal" value="0x07" />
<flag name="center" value="0x11" />
        …
</attr>
     …
</resources>
```

<attr>的格式如下：

```
<attr name="[ATTR_NAME]" format="[FORMAT]" />
```

其中format可以是string、dimension、boolean等一系列常用单

位，还可以是enum枚举类型，或者flag这种“或运算”的数值。比如上面 “gravity”的flag中包含了“center_vertical”和“center_horizontal”（分别为0x10和0x01），如果我们需要让资源同时具有这两种属性，就可以执行“或运算”得到0x11（实际上也就是“center”）。这种特性是enum所不具备的，所以单独以“flag”来表示。

如果读者仔细观察，会发现有的<attr>位于<declare-styleable>中，而有的<attr>则直接在<resources>中。那么，这两种形式有什么区别呢？

简单来讲，位于<declare-styleable>中的元素代表了某种特定资源的属性，而外围的属性则是“共有的”。换句话说，<declare-styleable>可以使用外围的属性值。举个例子，gravity这个属性在外围有完整定义，而且在很多<declare-styleable>中也会被引用到。比如TextView中：

```
<declare-styleable name="TextView">
<attr name="gravity" />
     …
</declare-styleable>
```

而且引用的地方没有再对它进行定义——它的属性值和外围的“gravity”一样。

整个文件中的<attr>是不允许重名的，即便它们位于不同的styleable中。

在xml文件中使用属性值时，首先要引用它的xmlns。比如要使用android系统提供的这些预定义属性，则需要：

xmlns:android=http://schemas.android.com/apk/res/**android**

如果是后期自己添加的属性，这里的URL地址就要转换成相应的包路径。

所有属性最终会被ADPT工具自动生成R.java中的一个类成员变量，供应用程序代码调用。

比如View组件有如下属性定义：

```
/*frameworks/base/core/res/res/values/attrs.xml*/
<declare-styleable name="View">
<attr name="id" format="reference" />
<attr name="tag" format="string" />
<!-- The initial horizontal scroll offset, in pixels.-->
<attr name="scrollX" format="dimension" />
<!-- The initial vertical scroll offset, in pixels. -->
<attr name="scrollY" format="dimension" />
<attr name="background" format="reference|color" />
…
```

View相关属性生成的结果：

```
    /*R.java*/
public static final int[] View = { 16842851, 16842852, 16842853,
16842965, 16842966, 16842967, 16842968, 16842969, 16842970, 16842
…
public static final int View_background = 12;
public static final int View_clickable = 29;
public static final int View_contentDescription = 41;
public static final int View_drawingCacheQuality = 32;
public static final int View_duplicateParentState = 33;
public static final int View_focusableInTouchMode = 19;
public static final int View_hapticFeedbackEnabled = 39;
public static final int View_id = 8;
public static final int View_tag = 9;
public static final int View_scrollX = 10;
public static final int View_scrollY = 11;
…
```

这个R.java会放在一个名为“android”的包中，如Android 4.1中的范例如图15-2所示（Android 4.3也是一样的）。

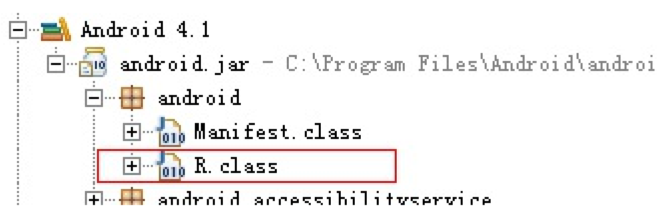

▲图15-2 范例的内容

这也同时解释了为什么我们使用“Android:[属性]”就可以访问到

R.java中的相应变量。

读者可能已经注意到上面R.java中有一个View数组，其后的成员变量值实际上是该数组的序号：

```
/*frameworks/base/core/java/android/view/View.java*/
public View(Context context, AttributeSet attrs, int defStyle) {
        this(context);
        TypedArray a = context.obtainStyledAttributes(attrs,
                         com.android.internal.R.styleable.View, d
          …
        final int N = a.getIndexCount();
        for (int i = 0; i < N; i++) {
            int attr = a.getIndex(i);
            switch (attr) {
                case com.android.internal.R.styleable.View_backgr
                    background = a.getDrawable(attr);
                    break;
                case com.android.internal.R.styleable.View_paddin
                    padding = a.getDimensionPixelSize(attr, -1);
                    break;
                 case com.android.internal.R.styleable.View_paddi
                    leftPadding = a.getDimensionPixelSize(attr, -
                    break;
```

上面这段代码是View的构造函数之一，我们在xml布局文件中的View组件就是通过这个函数来生成的。这里要解决的问题是：代码中如何获取通过xml指定的某个属性？

首先调用如下语句：

```
         TypedArray a = context.obtainStyledAttributes(attrs,
                         com.android.internal.R.styleable.View, d
```

可以看到，上面加深的部分就是前面所说的View数组。然后依据各个属性在数组中的位置（比如background是com.android.internal.R.styleable.View_background=12），就可以得到background属性对应的资源号，最后通过Resource类提供的各种加载方法就可以把资源提取出来了：

```
    public Drawable getDrawable(int index) {
        final TypedValue value = mValue;
        if (getValueAt(index*AssetManager.STYLE_NUM_ENTRIES, valu
```

```
            return mResources.loadDrawable(value, value.resourceI
        }
        return null;
    }
```

除了这些系统自带的资源属性外，很多时候我们还需要自定义新的属性值。比如，基于已有的View组件来扩展一个控件。升级后的View组件或多或少都会有一些新特性，这时我们就可以通过一定的方式来添加新的属性。

可行的方法有很多种，不过推荐读者使用declare-styleable。一方面这是Android系统内部所采用标准的属性添加机制；另一方面它在编译时就会做相应的错误检查，而不是等到代码运行时再报错（此时程序就会crash）。具体添加过程和前面的标准属性没有太大差异，此处不再赘述。

15.2　提供可选资源

为一个应用程序提供多种可选资源是实现设备适配的基础。比如对于同一张图片，我们可以提供高分辨率、中分辨率和低分辨率3个版本。一般的目录结构如下：

```
res/
     drawable/
          test.png
     drawable-hdpi/
          test.png
     drawable-mdpi/
          test.png
     drawable-ldpi/
          test.png
```

上面展示了test.png这个图像资源的几个不同版本。需要注意的是，它们都必须以相同的名字存储在各drawable目录下。当应用程序运行时，系统会依据当前设备的实际屏幕分辨率来选择最佳的资源。

除了分辨率外，同种资源之间还可有以下几种标签属性。

（注意：以下的标签修饰语是按照优先级从高到低的顺序排列的。）

- MCC和MNC（MCC and MNC）

MCC（Mobile Country Code）和MNC（Mobile Network Code）是网络运营商的全球唯一编号。其中MCC指国家码，后者则是网络编号。比如MCC-310属于美国，MCC-460属于中国。460-00代表中国移动，460-01代表中国联通。一般情况下，SIM卡中存有此卡的主归属地。

用作资源标签时，我们可以同时使用MCC，MNC组合，也可以只使用MCC。

比如：

- mcc460;

- mcc460-mnc00。

在程序编码时，可以通过Configuration类中的mcc和mnc属性来获取当前设备的这两个值。

- 语言和地区（Language and Region）

Android系统中采用的是ISO 639-1国际语言码，由两个字母组成。地区代码则遵照ISO 3166-1-alpha-2标准执行，也是两个字母。其中地区码是可选的，如果加上的话，需要在前面额外加上“r”。

例如：

- en（表示英语）；
- fr（表示法语）；
- en-rUS（表示英语和美国地区）；
- fr-rCA（表示法语和加拿大地区）。

在程序编码时，可以通过Configuration类的locale属性值来获取当前设备的语言地区信息。

- 最小宽度（Smallest Width）

格式是：

```
sw<N>dp
```

需要特别指出的是，这里的宽度其实是指传统意义上屏幕的宽和高中较小的那个。

例如：

- sw300dp;
- sw600dp。

如果用res/layout-sw600dp/来标志自己的布局资源，那就相当于告诉系统，屏幕的可显示尺寸必须在任何时刻都大于600dp（因为有时是横屏显示，有时是竖屏显示），才可以使用这一资源。和语言值不同，设备的最小宽度值是固定的，不会随着设置的变化而改变。

在AndroidManifest.xml中，可以通过“android:requiresSmallestWidthDp”属性值来表示此程序要求的最小宽度值。

在程序编码时，可以通过Configuration类中的smallestScreenWidthDp成员变量来获取当前设备的最小宽度值。

- 可用宽度（Available Width）

格式是：

w<N>dp

和上面的最小宽度不同，设备的可用宽度值随着当前是横屏还是竖屏会产生变化，即它表示的是当前真实的宽度值。如果读者的多种可选资源中都采用了这一标签进行修饰，那么系统会自动选择一个最接近于（但不超过）当前值的资源。

例如：

- w720dp；
- w1024dp。

可以通过Configuration类的screenWidthDp成员变量来获取当前的可用宽度值。

- 可用高度（Availabe Height）

格式是：

h<N>dp

这个标签和上面的可用宽度所表达的含义类似，只不过前面是宽

度，而这里是指高度。它同样会随着设备横、竖屏的变化而产生差异。当有多个可选资源时，系统会选择一个最接近（但不超过）当前真实值的资源选项。

我们可以通过Configuration类的screenHeightDp来获取设备的这一属性值。

- 屏幕大小（Screen Size）

因为市面上的屏幕尺寸非常多，而且还在不断地涌现出新的类型，所以我们不太可能为每种特定的尺寸大小分配一个选项。在Android系统中，将屏幕尺寸大致分为以下几类。

- small

尺寸类似于QVGA-低密度和VGA-高密度的屏幕，归属于这一类。最小的布局尺寸约为320*426 dp。

- normal

尺寸类似于HVGA-中密度、WVGA-低密度和WQVGA-低密度的屏幕属于这一类。最小的布局尺寸约为320*470dp。

- large

尺寸类似于VGA-中密度和WVGA-中密度的屏幕属于这一类。最小的布局尺寸约为480*640dp。

- xlarge

对于尺寸远超传统HVGA-中密度的屏幕属于这一类。最小布局尺寸约为720*960dp。这种尺寸的屏幕往往用于平板电脑而不是移动手持电话。

我们同样可以通过Configuration类中的screenLayout成员变量来获取当前设备的屏幕大小。

- 屏幕宽高外观（Screen Aspect）

这个属性是指当前屏幕的宽高比（aspect ratio）。有两种结果：

- long

长屏幕，如WQVGA、WVGA、FWVGA等。

- notlong

非长屏幕，如QVGA、HVGA、VGA等。

可以通过Configuration类中的screenLayout成员变量来获知屏幕是否为长屏。

- 屏幕方向（Screen Orientation）

分为两种，即：

- 竖屏（port）

屏幕处于竖屏状态（portrait orientation）。

- 横屏（land）

屏幕处于横屏状态（landscape orientation）。

显然这个值会随着用户的操作而变化，但我们可以通过Configuration类中的orientation成员变量来获知当前设备的屏幕方向。

- UI模式（UI Mode）

UI模式分为以下几种：

- car;
- desk;
- television;

- appliance。

它表示设备被放置在底盘（dock）时的模式，如汽车上的手机托盘、桌面托盘等。这个模式会随着用户的操作而改变，可以通过UiModeManager来开启和关闭这一功能。

- 夜间模式（Night Mode）

分为两种，即：

- night

当前处于夜间模式。

- notnight

当前不处于夜间模式。

如果夜间模式被设置为自动，那么系统会根据当前时间来自行决定是不是夜间模式。可以通过UiModeManger来开启或关闭这一功能。

- 屏幕像素密度（dpi）

和前面的屏幕大小类似，屏幕的密度种类也比较多，因而在Android系统中将dpi粗略地分为以下几类。

- ldpi

低密度屏幕，大约为120dpi。

- mdpi

中密度屏幕，大约为160dpi。

- hdpi

高密度屏幕，大约为240dpi。

- xhdpi

  超高密度屏幕，大约为320dpi。

- nodpi

  表示这些资源不希望被改变尺寸以适应屏幕。

- tvdpi

  介于mdpi和hdpi之间，大约为213dpi。主要用于电视产品，普通的应用程序并不推荐使用。

- 触摸屏的类型（Touchscreen Type）

  有如下两种可选值。

- notouch

  设备不带触摸屏。

- finger

  触摸屏是通过手指操作的。

  通过Configuration类的touchscreen成员变量，可以获知当前设备的触摸屏类型。

- 键盘可用性

  当前键盘的状态有3种可能值。

- keysexposed

  设备有可用键盘。如果当前的软键盘被启用，那么即便设备没有键盘或者键盘不可用，这个状态仍可能有效。

- keyshidden

设备有键盘，但当前被隐藏，而且没有软键盘启用。

- keyssoft

设备当前的软键盘启动，即便它处于可见或不可见状态。

这个值在运行过程中可能会变化，可以通过Configuration类的hardkeyboardHidden和keyboardHidden变量来获知当前状态。

- 首选文本输入方法（Primary Text Input Method）

这个名字可能会引起误解，其实它是关于设备按键的。

- nokeys

设备不带有用于文本输入的按键。

- qwerty

设备有一个qwerty键盘，无论它是否可见。

- 12key

设备有一个12键的键盘，无论它是否可见。

可以通过Configuration类的keyboard变量来获知当前的首选文本输入方法。

- 定位键可用性（Navigation Key Availability）

定位键是否可用（注意：这里不是指GPS导航的定位，而是光标定位）：

- navexposed

定位键对用户可用。

- navhidden

定位键不可用。

这个值也会在运行中动态变化，可以通过Configuration类的navigationHidden变量来获取当前值。

- 主要的非触摸屏定位方式（Primary non-touch Navigation Method）

这个属性是指除触摸屏以外的定位方法，有以下几种。

- nonav

设备除了触摸屏外没有其他定位方式。

- dpad

设备配备dpad来定位。

- trackball

设备配备轨迹球来定位。

- wheel

设备有方向滚轮用于定位，不常用。

可以通过Configuration类的navigation变量来获取设备当前的非触摸屏定位方式。

- 平台版本（Platform Version）

指的是设备所支持的API等级值，如v3、v4、v8等。

15.3　最佳资源的匹配流程

针对大多数APK应用程序，开发人员都会提供各种不同版本的资源。那么，系统在运行时是如何动态选择最合适的资源来使用呢？理解最佳资源的匹配流程至少有如下两个好处。

- 当设计应用程序时，我们可以有针对性地提供正确的资源。
- 对于我们适配多种设备有重要的指导意义。

最佳资源的匹配规则如图15-3所示。

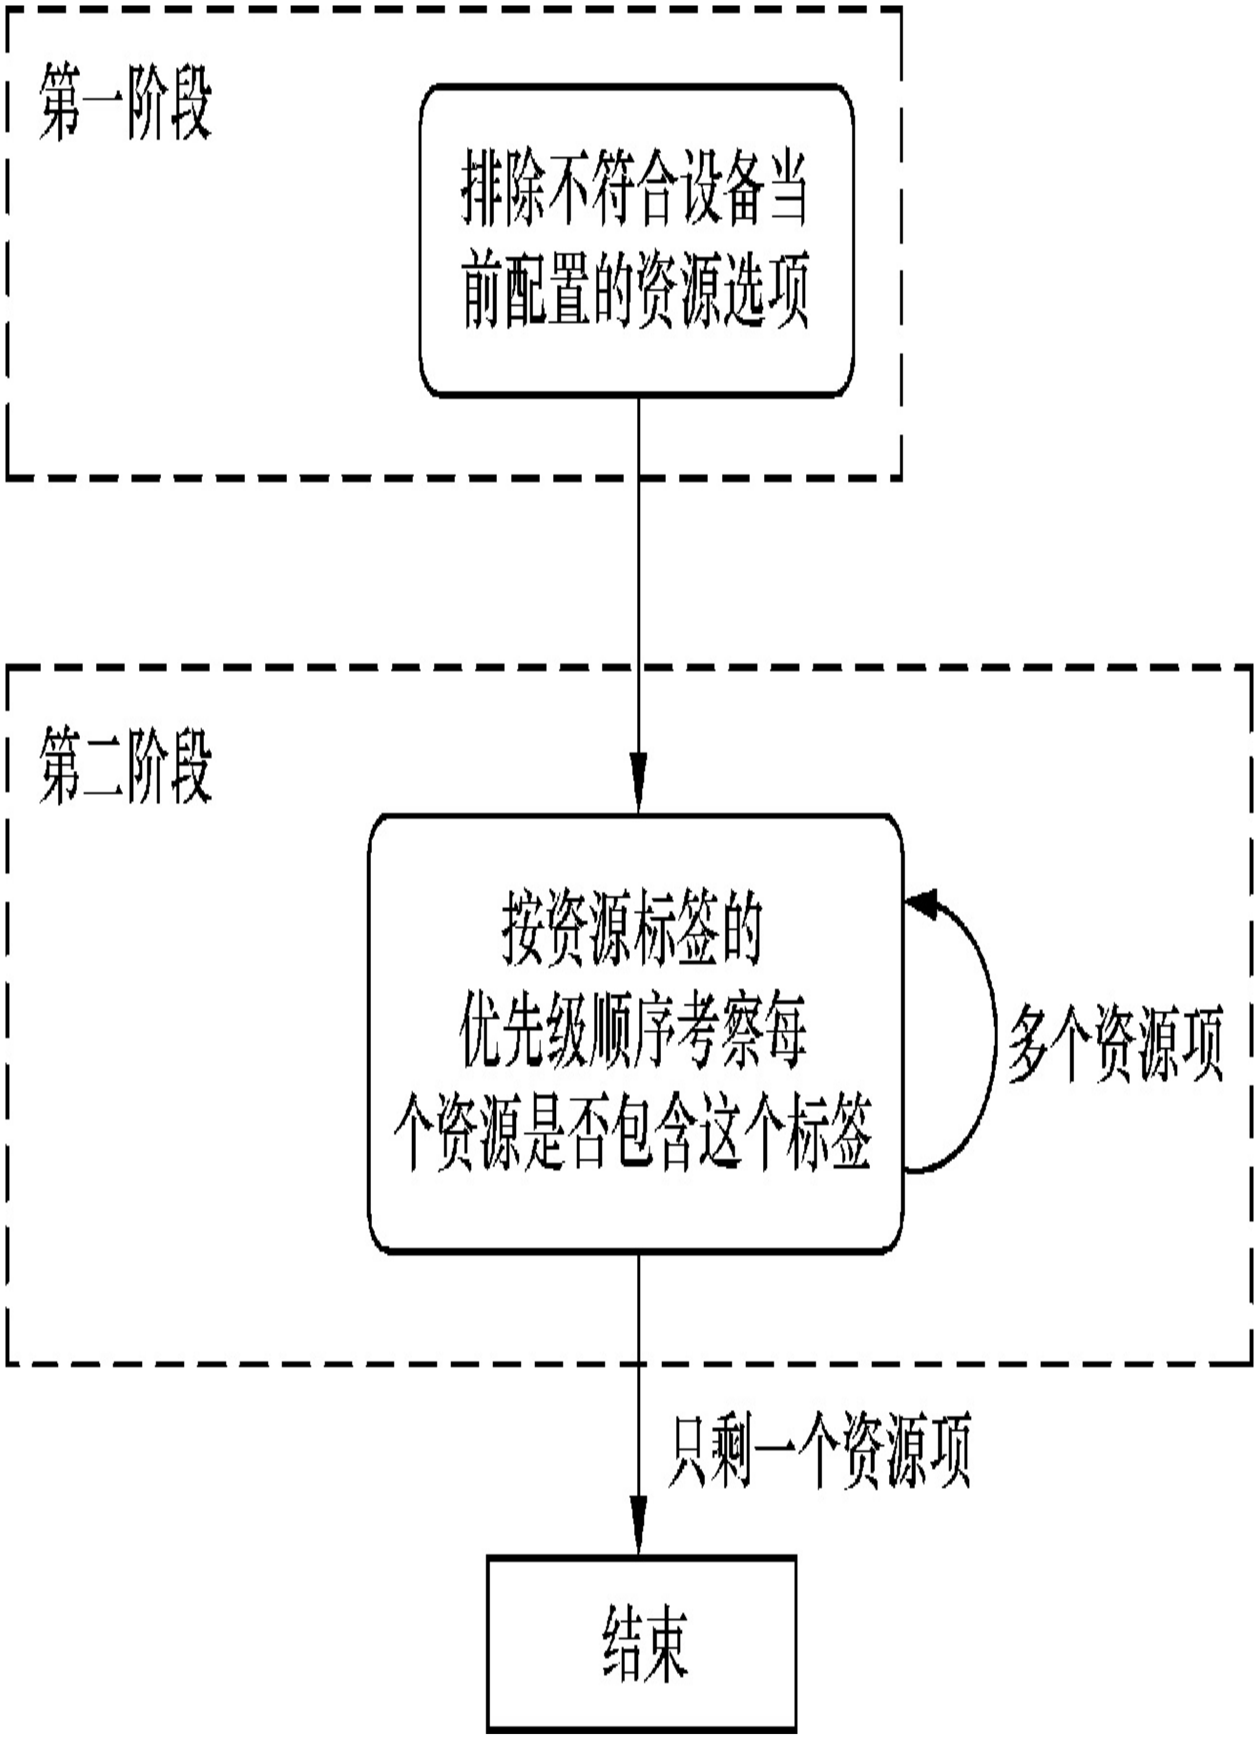
第一阶段
排除不符合设备当前配置的资源选项
第二阶段
按资源标签的优先级顺序考察每个资源是否包含这个标签
多个资源项
只剩一个资源项
结束

▲图15-3　资源的匹配过程

我们以官方文档中的一个例子来具体分析匹配流程。

假设某应用程序中的drawable资源有如下几种选项：

- drawable/；
- drawable-en/；
- drawable-fr-rCA/；
- drawable-en-port/；
- drawable-en-notouch-12key/；
- drawable-port-ldpi/；
- drawable-port-notouch-12key/。

设备的当前配置为：

- Locale = en-GB；
- Screen orientation = port；
- Screen pixel density = hdpi；
- Touchscreen type = notouch；
- Primary text input method = 12key。

匹配目标：逐一排除资源选项，直到只剩下唯一的选择（即选择最优解的过程）。

匹配过程：分为两个阶段。

- 第一阶段：筛选掉与设备当前配置不相符的资源选项

在淘汰过程中，对于资源选项里没有显式写出来的配置，不作为评判标准；而资源选项里显式写出来的，符合当前配置的可以通过筛选，否则直接淘汰。

比如上面例子中，第3个资源选项中的“fr-rCA”及第6个选项中的“ldpi”都不符合当前的设备配置，应该被淘汰。

不过还需要指出的一个特例是，Android明确规定：density标签不在第一阶段的淘汰范围内。因而，第一轮游戏结束时结果如下：

- drawable/;
- drawable-en/;
- drawable-fr-rCA/（淘汰）;
- drawable-en-port/;
- drawable-en-notouch-12key/;
- drawable-port-ldpi/（作为特例被保留下来）;
- drawable-port-notouch-12key/。
- 第二阶段：选择最优解

经过第一轮的“资格淘汰赛”后，剩余的选项都是完全符合设备当前配置要求的（除了特例外）。因此，接下来这一轮竞赛中我们需要在所有“选手”中选择一个最优秀的。这就好比才艺比赛一样，我们首先设定了参赛者的入门条件（阶段一）；而只有通过初步筛选后，才再按一定的优先级标准来评定每个选手的表现（阶段二）。比如歌唱技巧是最重要的考察因素，最后是舞台表现力，最后是表情张力等。

前一小节我们介绍资源标签时采用的内容编排顺序，就是根据它们的优先级来定的。应用到这个例子中：

Step1. 我们先选择MCC，MNC来考察，发现没有任何“选手”包含这个标签。

Step2. 选择语言与地区标签。由于当前配置是en-GB，所以没有带这个标签的“选手”被淘汰。结果如下：

- drawable/（淘汰）;
- drawable-en/;

- drawable-en-port/;
- drawable-en-notouch-12key/;
- drawable-port-ldpi/（淘汰）；
- drawable-port-notouch-12key/（淘汰）。

Step3……

接下来的步骤中我们重复利用这一规则，直到最终只剩一个“选手”为止。在这个例子中，“冠军”要直到“屏幕方向”标签时才出现（设备的当前屏幕方向是port）：

- drawable-en/（淘汰）；
- drawable-en-port/（胜出）；
- drawable-en-notouch-12key/（淘汰）。

15.4 屏幕适配

屏幕适配是确保Android应用程序兼容性一个至关重要的环节。我们知道，Android设备种类繁多，这意味着APK开发者不可能只针对某种特定型号的设备来做匹配（当然，如果你的应用程序只打算运行在有限的已知设备上，就可以做有针对性的适配），而应尽可能考虑到所有可能出现的设备——因而如何对这些设备的屏幕进行合理有效的分类是首先要解决的难点。

15.4.1 屏幕适配的重要参数

本小节中，我们先来看看Android系统中和屏幕相关联的几个重要参数。

- 屏幕分辨率（Screen Resolution）

分辨率是指屏幕上物理像素的多少，它直接反映了屏幕显示的精细

度。通常像素点越多，画面就越清晰，可以显示更多细节；相反，像素点少的屏幕显示出的图像容易出现锯齿，画面相对模糊。常见的屏幕分辨率有QVGA（320*240）、VGA（640*480）等。

但是在Android的设计理念中，我们并不能直接去使用分辨率——而是由以下所提到的屏幕密度和大小来做组合表达。

- 屏幕密度（Screen Density）

单位间距内物理像素点数量的多少，以dpi（Dots per Inch）表示。Android系统将屏幕密度分为4类，分别为：

- ldpi（low）；
- mdpi （medium）；
- hdpi（high）；
- xhdpi（extra high）。
- 屏幕尺寸（Screen Size）。

一般是指屏幕的对角线尺寸值，用inch表示。比如常用的尺寸包括3.7inch，4.0inch， 6.1inch等。在Android系统中，将所有可能的屏幕尺寸分为4种，即：

- Small;
- Normal;
- Large;
- xlarge。

屏幕密度和尺寸大小（small，normal，large等）并不是根据绝对的某个范围值来划定的，如图15-4所示。

再来看看Google官方发布的一份数据——截至2012年7月，市面上

Android产品的屏幕大小和密度的分布（这份报告也可以作为应用开发者的市场参考）如表15-2所示。

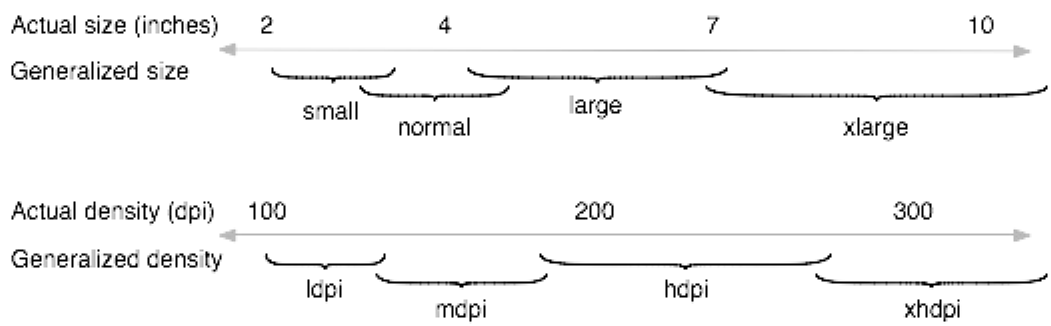

▲图15-4　Android系统中屏幕尺寸和密度对照图

表15-2　不同屏幕尺寸与密度的Android设备的市占率

	ldpi	mdpi	hdpi	xhdpi
small	1.7%		1.3%	
normal	0.4%	12.9%	57.5%	18.0%
large	0.2%	2.9%		
xlarge		5.1%		

由此可见，市面上最常见的Android设备的屏幕尺寸为normal，屏幕密度为hdpi，如图15-5所示。

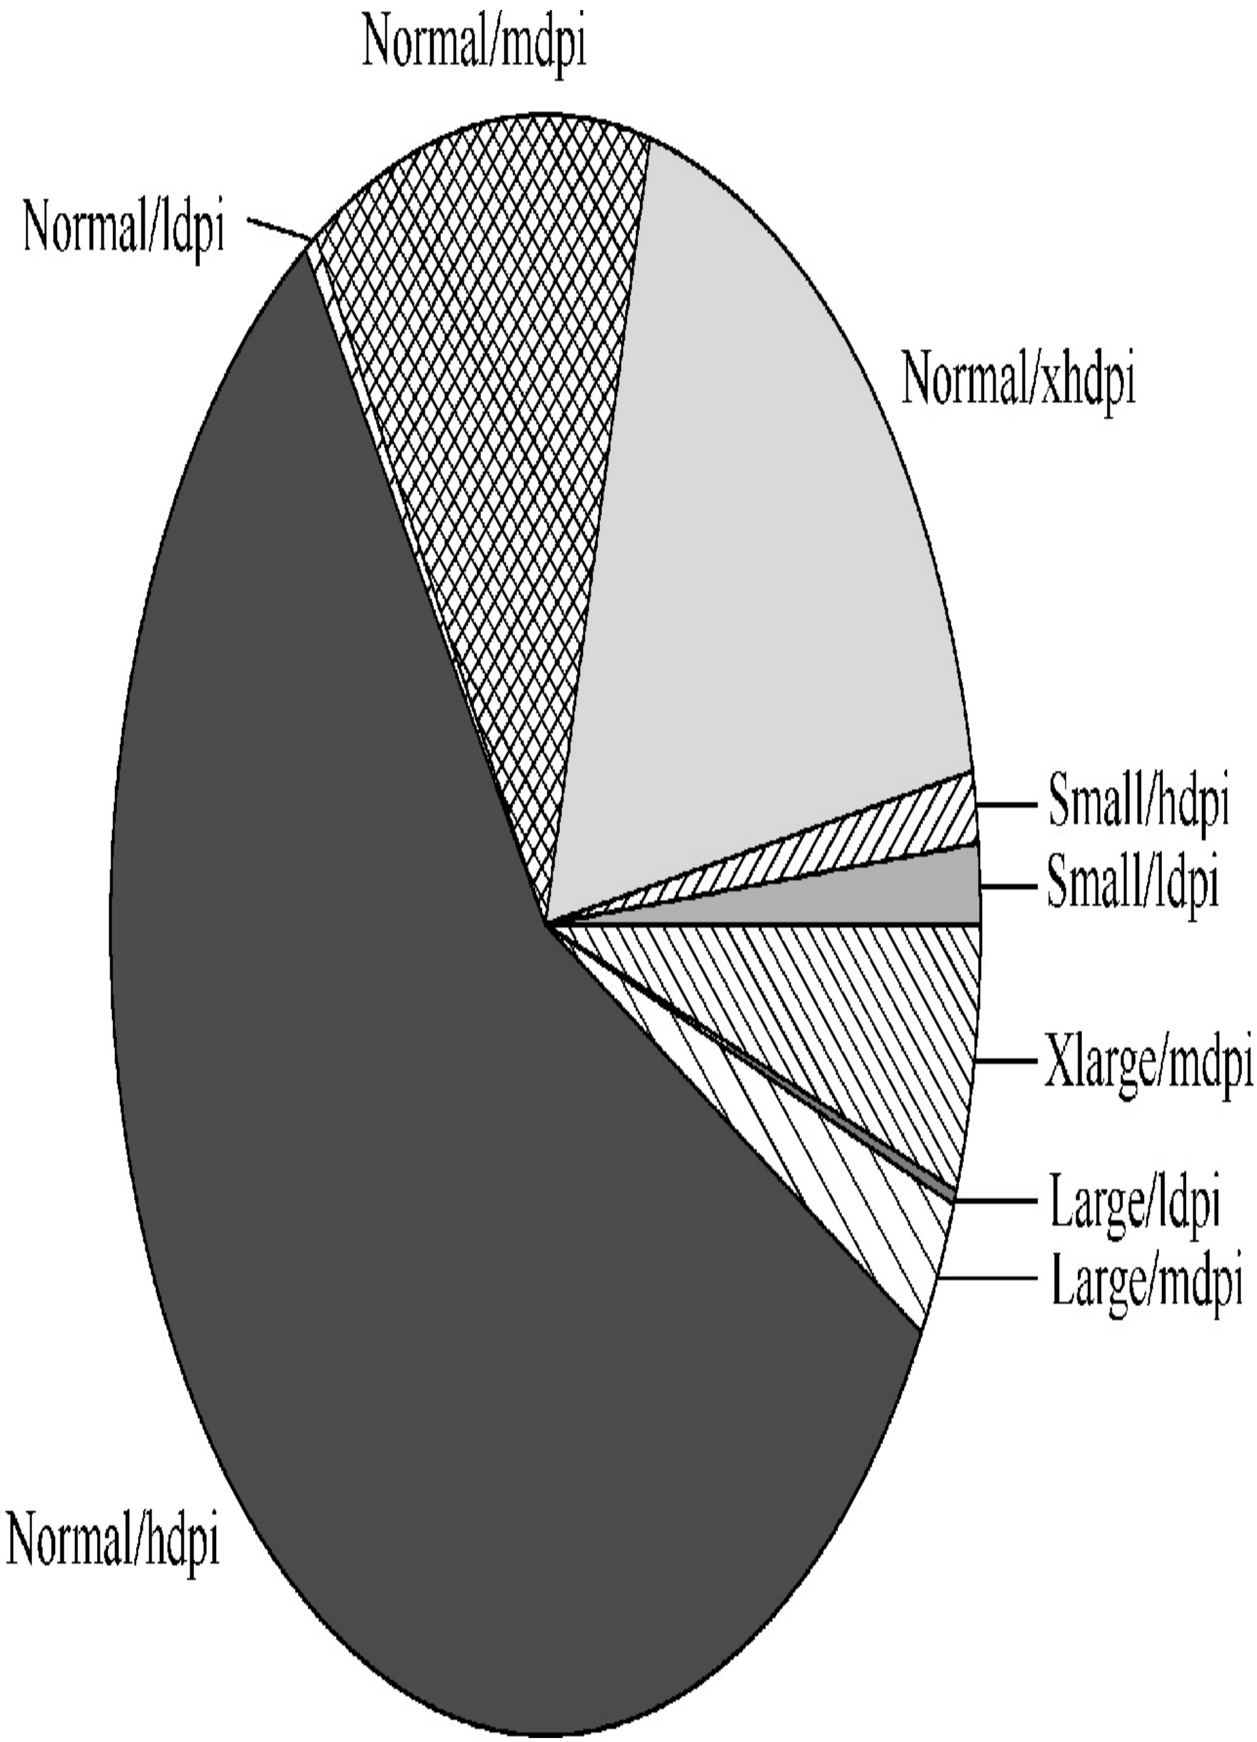
Normal/mdpi
Normal/ldpi
Normal/xhdpi
Small/hdpi
Small/ldpi
Xlarge/mdpi
Large/ldpi
Large/mdpi
Normal/hdpi

▲图15-5　屏幕尺寸占比

- 屏幕宽高比（Aspect Ratio）

屏幕的宽和高的比值，称为Aspect Ratio。比如16:9——如果宽度为16，那么高度值为9。

- 屏幕方向（Screen Orientation）

以用户的视线方向为准，如果宽高比大于1，称为横屏（landscape），否则就是竖屏（portrait）。

- 设备独立像素（Density Independent Pixel）

DIP是为了更好地自适应不同的屏幕而提出的概念。中心思想是dip的值会随着当前屏幕的密度变化而做相应改变。它的计算公式为：

```
Px = dp * (dpi /160)
```

也就是说，在dpi为160的设备上，dip数值和屏幕物理像素是一样的；而在dpi为240的机器上，这个值会是实际值的1.5倍。

下面以Android官方提供的一个例子来解释采用dip的好处。

假如有3台设备，它们的屏幕尺寸是一样的，而密度分别为ldpi、mdpi和hdpi，那么采用dip和不采用dip的区别可以参见图15-6和图15-7。

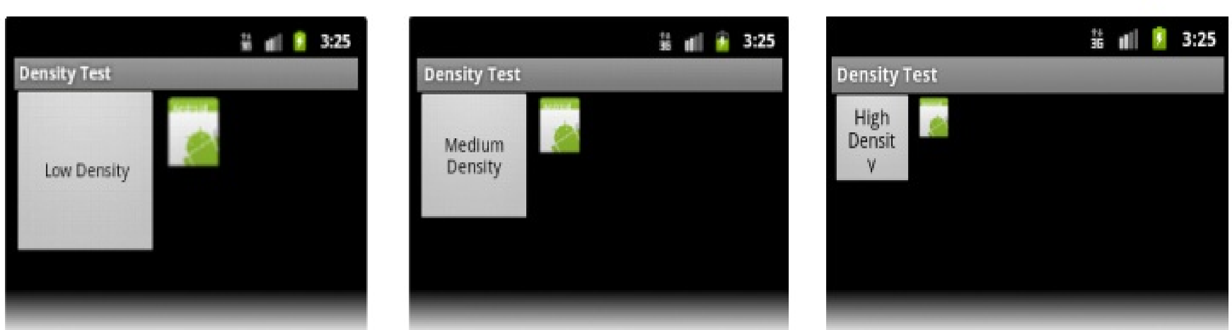

▲图15-6　不采用dip时的情况

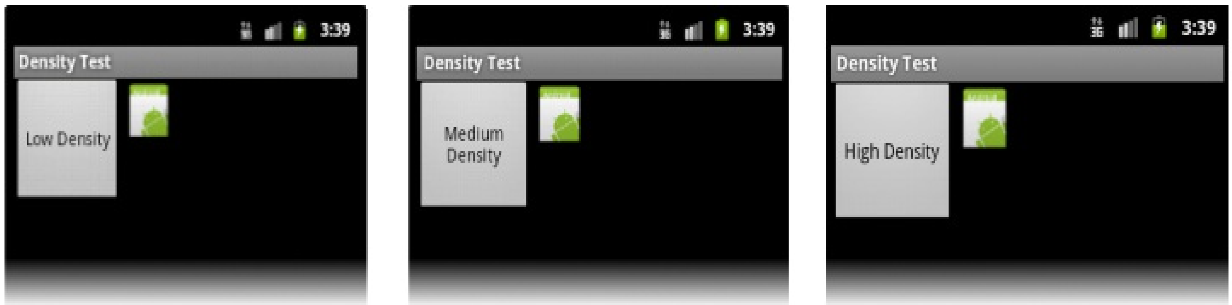

▲图15-7　采用dip时的情况

由此可见，对于不采用dip来描述的物体（比如一个Button），随着屏幕密度的增大，它的大小相对于整个屏幕在缩小；而使用dip描述的情况则没有这个问题，即它可以基本保持此物体的相对尺寸。显然后一种效果才是我们所期望的，因为前一种很可能导致UI界面的变形。

当然，dip虽然可以在某种程度上帮助我们去更好地适应不同密度的屏幕，但它也并不是万能的。大家可以想一下，一个尺寸标注为N dp的物体，它在不同屏幕上的实际物理尺寸（单位inch）为多少呢？

计算公式如下：

```
physical_size = N*(dpi/160)*(1/dpi)=N/160
```

其中dpi代表了这款屏幕的密度。

我们得出一个结论：

用dp标注的物体，它在不同屏幕上的实际物理尺寸理论上将保持不变

换句话说，N为160的物体，它在不同屏幕上的实际物理尺寸将为1 inch；N为320的物体，它在不同屏幕上的实际物理尺寸将为2 inch。

假设全世界所有Android设备的物理屏幕都是同一个Size，那么这无疑可以解决适配问题——但显然这是不现实的。

那么这将导致什么问题呢？举个例子来说，假设有一个View的宽度设置为160dp，那么它在1inch宽的屏幕上，其宽度与屏幕一致；但在一个2 inch宽的屏幕上时，它的宽度则仅有屏幕的一半。这种情形下采用

（或者说只采用）dp机制，个人认为就不是一个明智的选择了。

15.4.2 如何适配多屏幕

Android系统支持同一应用程序在多种屏幕上使用。为了达到这一目标，系统本身已经做了不少工作——按照Android的设计思想，它将尽量为开发者考虑各种可能发生的情况。比如它会根据当前设备的具体参数自动为应用程序选择最佳的显示资源；适当的时候还会对资源进行修正，以满足实际需求等。

不过，Android系统本身也不是万能的，而且有时候“智能”是把“双刃剑”——在无法准确掌握其工作原理的情况下，越“智能”的机制反而越有可能违背我们的意愿。因此，理解Android系统在支持多屏幕时所做的工作，才能“取其精华，去其糟粕”，真正将Android的设计精髓运用得“淋漓尽致”。

- Android系统为当前屏幕配置选择最佳资源的流程

这一过程和我们前一小节讨论的最佳资源匹配过程一致。Android系统将根据现有的资源标签以及实际的设备屏幕参数，来寻找最合适的资源类型。但是，如果经过两轮匹配后，还是没有任何符合要求的资源（即所有可选资源均被淘汰），那么它会选择默认的资源配置（没有被贴上标签的资源）。

默认资源是应用程序在不得已之情况下的选择，开发者应该提供这类资源以备“不时之需”。

- 为不同的屏幕尺寸提供多种layout布局

我们已经在前几节讨论过如何在应用程序中提供多种“可选资源”，如果读者还不是很清楚，建议回头复习一下，这里不再赘述。

不同的屏幕尺寸，所需的layout布局通常也有所差异。举个例子，有一个显示9个按钮控件的layout，它在大屏幕上可以正确显示；但一旦切换到小屏幕上，即便这9个控件都可以被显示出来，也可能会被压缩（由此产生的用户体验效果是很差的）。因而我们建议对于尺寸跨度大的屏幕，应用程序应该提供多种layout布局文件。

- 为不同的屏幕方向提供多种layout布局

不同方向屏幕布局的差异如图15-8所示。

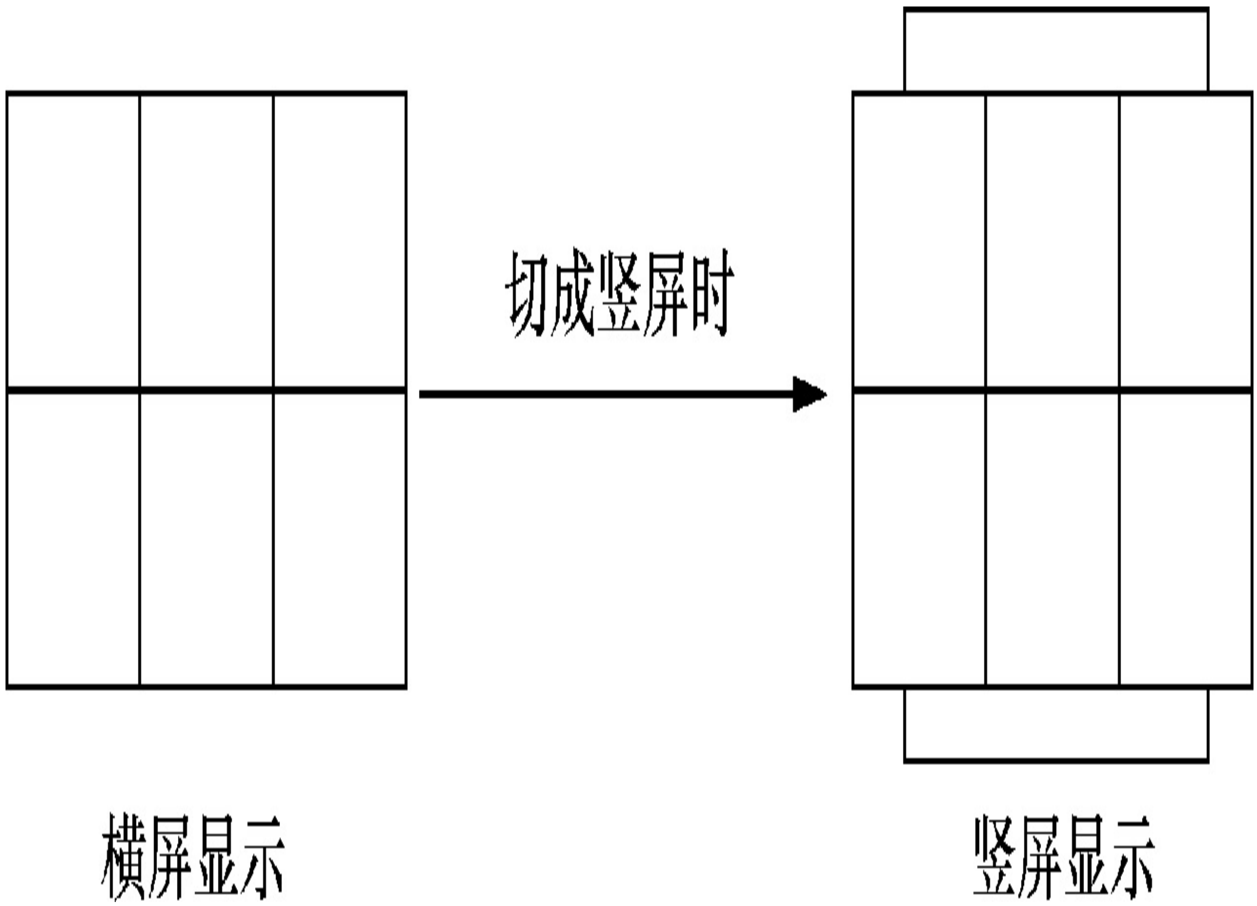

▲图15-8 横屏和竖屏的布局差异

由图可知，当设备处于“横屏”状态时，可以正常显示2*3个尺寸一样的控件；然而，当屏幕方向改为“竖屏”时，情况发生了很大变化。如果我们仍然采用原先的布局，效果一定不会很好。因此，为不同的屏幕方向提供合适的布局已成为应用开发者的共识。

- 为不同的屏幕密度提供相应的图片资源

我们知道，在尺寸不变的情况下，密度越大，所需的像素点越多，显示越细腻。而如果应用程序所提供的图片资源没有考虑到这一点，那么在实际运行时很可能被拉伸，从而造成显示效果相对模糊。

- 显式声明应用程序支持的屏幕类型

系统提供了<supports-screens>元素来让应用程序在AndroidManifest文件中显式声明其所支持的屏幕种类。除此之外，这个元素还可以控制屏幕的兼容模式（Screen Compatibility Mode）——它是为解决应用程序在大屏幕上显示时出现的困难而专门设计的。对于不同的Android版本，其表现和设置都有所差异。详细信息可以参见官方文档。

<supports-screens>的语法如下：

```
<supports-screens android:resizeable=["true"| "false"]
android:smallScreens=["true" | "false"]
android:normalScreens=["true" | "false"]
android:largeScreens=["true" | "false"]
android:xlargeScreens=["true" | "false"]
android:anyDensity=["true" | "false"]
android:requiresSmallestWidthDp="integer"
android:compatibleWidthLimitDp="integer"
android:largestWidthLimitDp="integer"/>
```

当开发人员显式地声明了所支持的屏幕类型后，可以有效阻止那些不符合要求的设备安装此应用。表15-3给出了这一元素的属性描述。

- 支持特定的屏幕

有的应用程序是被设计专门运行于某些特定设备上的。在这种情况下，我们可以采取一定的限制方式来避免不符合要求的设备安装这些应用程序。

表15-3　<supports-screens>的属性值

属　　性	描　　述
android:resizeable	表示程序是否可以调整尺寸默认值为“true”。如果是“false”的话，系统会在大屏幕时开启屏幕兼容模式

android:smallScreens	是否支持small尺寸的屏幕默认值为“true”
android:normalScreens	是否支持normal尺寸的屏幕默认值为“true”
android:largeScreens	是否支持large尺寸的屏幕默认值随版本而变化，但如果是“false”，将可能启动屏幕兼容模式
android:xlargeScreens	是否支持xlarge尺寸的屏幕和上面的属性类似，这个属性的默认值也会根据版本的不同而有所差异，因此建议开发者最好每次都能显式写出。如果是“false”，通常也会启动屏幕兼容模式
android:anyDensity	是否支持所有密度类型的屏幕。这意味着程序提供了各种可选资源以满足不同屏幕密度的需求从Android 1.6开始，默认值是“true”
android:requiresSmallestWidthDp	指定此应用程序所能支持的最小smallestWidth。可以参见前两小节中关于“最小宽度（Smallest Width）”的描述

android:compatibleWidthLimitDp	这个属性可以让“屏幕兼容模式”作为一种用户选项体现出来。比如，一台设备的最小宽度大于这里的值，那么兼容模式将会被启动。在这种情况下，用户将可以通过一个按钮手工控制屏幕兼容模式
android:largestWidthLimitDp	和上面的属性类似，不同之处在于它强制使用屏幕兼容模式，即用户不能通过按钮来手工选择是否需要开启兼容模式

<compatible-screens>可以用来实现这个功能。它的语法如下：

```
<compatible-screens>
     <screen android:screenSize=["small" | "normal" | "large" | "
          android:screenDensity=["ldpi" | "mdpi" | "hdpi" | "xhdp
    ...
</compatible-screens>
```

每个<screen>项用来表示一种屏幕兼容配置，一个AndroidManifest文件里可以有多个<screen>描述。其中的screenSize和screenDensity是必须成对出现的，否则会被视为无效。

对于一些应用程序的服务商（比如Google Play），在用户下载应用程序时都会有相应的检测机制来保证用户使用的设备是否符合<compatible-screens>的限制。一方面这将有效阻止达不到要求的设备安装使用此应用程序，而另一方面可能会阻隔潜在的用户群。因此在发布程序时开发商一定要想清楚，是否一定要采用这一属性。

- 布局时的注意事项

布局时，应尽量避免使用“绝对”的表示方法。比如不用或尽量少用AbsoluteLayout（从Android 1.5开始，已经被废弃）；杜绝以“物理像素点”为单位来描述组件属性，而应采用dip和sp来分别表示布局大小和字体大小。

实践证明，只有严格遵循以上几点要求的应用程序，才能在“屏幕适配”这一难关中“脱颖而出”，也才能为用户提供尽可能完美的UI体验。

15.4.3　横竖屏切换的处理

横竖屏切换事件在终端设备中的发生频率非常高，因而也是应用程序在开发过程中需要特别注意的。Android系统在处理这一事件时，通常会重新加载和刷新Activiy（因为横竖屏更改有很大机率会带来界面的变化），所以开发人员需要在必要的情况下重载这一行为以避免不可预期的问题发生。

我们首先分析一下发生横竖屏切换时系统的具体处理流程，以便大家可以根据自己的需求做出正确的选择。

Step1. 根据系统设置的不同，有两种可能：

- 系统设置中关闭了屏幕旋转功能

此时系统不会主动检测屏幕的旋转事件，所以正常情况下应用程序也就不会感应到屏幕方向的变化了。当然，这并不代表应用程序不能主动获取屏幕的横竖屏切换事件。事实上不少应用程序因为自身的功能需求（如视频播放器在横屏时实现全屏显示），会自行向传感器注册并获取信息——这样一来就摆脱了系统设置的限制了。

- 系统设置开启了屏幕旋转功能

此时会向Sensor注册一个监听请求，具体源码实现在WindowOrientationListener.java中。一旦有事件发生，将进入下一步

Step2. 在经过一系列的前期处理后，系统会判断应用程序所设置的android:screenOrientation值。关于这一属性的主要可选值和释义如表15-4所示。

表15-4　android:screenOrientaion释义

Value	Description

unspecified	默认值。由系统根据实际情况做选择
landscape	横向
portrait	纵向
user	用户当前的首选方向
sensor	根据传感器来确定方向
nosensor	不使用传感器来确定方向

由此可见，如果应用程序想强制横屏或者竖屏显示，可以考虑使用这个属性来做相应配置。

Step3. 如果确定应用程序需要响应横竖屏切换，那么正常情况下系统会重新启动一次Activity的生命周期流程。但这可能并不是开发人员所需要的（比如用户体验不好）。那么有没有办法阻止系统的这一默认形为呢？

答案是肯定的，利用android:configChanges就可以做到。当然，除了正确设置这一属性外，代码中还需要增加对onConfigurationChanged函数的重载实现。这样就可以迫使系统改变常规的处理流程，而改由onConfigurationChanged来全权负责。

上述3个步骤是屏幕方向切换后系统和应用程序的通用处理流程，在不同设备上的具体表现可能会有些差异（取决于设备厂商的定制策略）。建议大家在实际项目开发中能针对目标设备做一次全面的测试，以尽量避免异常问题的发生。

第16章
Android字符编码格式

在工程项目开发过程中，让不少工程师很头痛的一个问题就是“乱码”。特别是当产品涉及国际化时，情况就更加错综复杂了。Android系统在全球范围内都获得了广泛使用，因而字符串国际化的问题不容小觑。

“万变不离其宗”，本章我们将首先从字符串编码的基础知识入手，然后过渡到Android项目中的实际解决方案。很多时候，只要基础打扎实，问题也就迎刃而解了。

16.1 字符编码格式背景

从计算机存储的角度来讲，并不存在字符编码格式的概念，因为任何资源在计算机系统中都以二进制进行存储。就好比一门语言——只有双方基于同样的发音标准才能互相理解，编码格式也就是编码者与解码者之间的规范；而且不论是汉语、英语、法语，核心目的都是让双方能够正常沟通。编码格式的宗旨也类似，因而格式本身可以有多种形式，只要通信双方都清楚每个字节的含义即可。

我们接下来先看看几种常见的字符编码格式。

- ASCII

这可能是大家最熟悉的一种编码，我们简单叙述一下。ASCII只需一个字节，占用的空间很小，不过它容纳的字符数也相当有限。除了128个字符作为常规使用外（最高位为0，用于英文字母、数字、控制字符等），另128个则是“扩展ASCII”。后面的这部分ASCII实际上没有统一的国际标准，因而被“各方人士”利用起来用于自己的编码规范，这就是ANSI。

- ANSI

ANSI码（American National Standards Institute）实际上是各个国家对ASCII以外字符的扩展，通常占2个字节。比如中国是GB2312，日本则是JIS。可想而知，这些“各地”编码是不兼容的。因为ASCII已经占用了0x00-0x7F之间的范围，所以ANSI必须只使用这一范围以外的数值。另外，ANSI中的ASCII字符仍然只占用1个字节。举个例子，“我是第1”的ANSI编码是7个字节，其中最后的“1”只占用1个字节，其他的中文字符则各占2个字节。

- 中文简体/繁体

理论上简体和繁体字符和编码没有太大关联，它们更多的是属于“显示”范畴的区别。举一个例子，一个繁体字同样也可以用简体字的方式显示出来。换句话说，我们先使用与该字符相同的编码标准将其“理解”出来，接下来要怎么显示就是另外一回事了。不过现实中简体/繁体与编码格式还是息息相关的。

中文显示由于地域、历史、政治等多方面的原因，最初主要有3种编码方式，即GB2312、Big5和HKSCS。第一个大家应该比较熟悉，它是由我国国家标准总局于1980年发布的，因而也被称为GB2312-80或者GB2312-1980。它收录了6763个汉字和682个非汉字，分为94区，每区又有94位。这一标准规定的中文字符虽然能满足大众的常规需求，但对于古汉语等罕见字则还是无法处理。另外它和我国台湾地区的Big5也是不兼容的，因而造成了不少麻烦。基于这些因素，GBK编码应运而生，于1995年12月发布。这个标准不但完全兼容旧的GB2312，而且包括了ISO 10646中的全部中日韩汉字以及BIG5中所有汉字。ISO 10646是ISO组织发布的编码规范，即我们熟知的UCS（Universal Character Set），它又兼容于Unicode码。关于UCS与Unicode之间的“恩恩怨怨”还会牵扯出很多事情，有兴趣的读者可以自行了解。

随后几年，即2000年和2005年，中国又在GBK基础上进行了进一步升级，这就是GB18030系列。它们不但收录了汉字，而且将藏族、蒙古族、傣族等少数民族的字符都合成进来，形成了一个超大型的编码规范。虽然标准很多，但国家颁发的这些字符集规范是向下兼容的。

- Unicode码

这也是我们比较熟悉的一种规范，只不过其中又有很多繁杂的细节，因而大部分人“只知其一，不知其二”。由于历史原因，计算机发展初期并没有充分考虑国际上众多语言和字符的存在。这也难怪，谁也不会预料到计算机后来的发展会如此迅猛，以致成为“走进千家万户”的一种日常用品。后期的问题接踵而至，全球各国都已经意识到统一编码标准的必要性，于是Unicode国际组织出现了。这个组织的意愿就是将世界上所有的字符统一用一种编码方式来表达，以解决各种各样的不兼容问题。虽然Unicode码和GB码、BIG5码都不兼容，但它还是未来发展的一个大趋势，是一个软件产品能否国际化的关键，因而我们有必要对它进行更详细的讲解。

16.2 ISO/IEC 8859

在学习Unicode之前，我们先来了解下8859系列规范。它是由ISO和IEC（International Electrotechnical Commission）共同推出的协议，共有15部分（1～16，但是12被废弃），如ISO/IEC 8859-1、ISO/IEC 8859-2等。

虽然ASCII码在英语中已经足够使用，但是很多以Latin为基础的其他语言（主要是欧洲国家），却需要更多额外的字符来表示。8859就是利用了ASCII以外的编码空间来表示这些字符。所以8859实际上能表达的字符数相当少，每个子集（比如8859-1）的范围是0xA0-0xFF即96个字母或者符号，详表可查询官方说明，我们这里不逐一列出。

显然，8859这样的字符协议是没有办法满足像中文这样的语言的。我们的“方块字”和英语语言有很大区别。英文无论是什么词，都是由最基础的26个字母组成的。比如“Answer”这个词在英文中是由6个字母拼起来的；同样“Question”也是由字母组合的。而中文中不论是“回答”还是“问题”中的任何一个字，都不能拆分成类似英文字母这样的组成元素。这就注定了“中文字符集”必须是足够庞大的，才能容纳下古往今来的所有汉语字符。

Unicode出现后，ISO/IEC 8859也逐步向其靠拢，目前它的15个子集都可以在Unicode/UCS中找到对应项；而且原8859的部分工作组也已经转向ISO/IEC 10646。

16.3 ISO/IEC 10646

说到10646协议大家可能会觉得很陌生，其实它是国际标准的一个编号，全称是“Information technology — Universal multiple-octet coded character set”，也就是UCS。这个标准于1993年正式颁布，规定了字符集的总体框架，如表16-1所示。

也就是说，UCS可表达的范围是128256256*256，这是一个非常大的数值。不过实际上UCS的范围不能超过21bit，即0x000000-0x10FFFF（即1114111）。

表16-1　UCS的结构简图

Architecture	Group	Plane	Row	Cell
Bit	8	8	8	8
Range	0x00-0x7F	0x00-0xFF	0x00-0xFF	0x00-0xFF

它的第一个平面（第0组的第0平面中的0x0000-0xFFFD），被称为“Basic Multilingual Plane”（BMP）或者“Plane 0”，用于容纳最基本的字符。1993年发布的ISO 10646-1添加了BMP中的内容，而2001年ISO 10646-2版本则进一步更新了BMP范围外的内容。到了2003年，这两个规范被合成为ISO 10646标准，并仍在不断完善中。

16.4 Unicode

前面说过，Unicode是为了容纳世界上所有文字及符号而诞生的。可想而知，当时以这个目标为宗旨创建的组织肯定不止一个。其中，最有名的就是Unicode和ISO中的10646项目。不过值得庆幸的是双方在后期都意识到这个世界上不应该出现两个不兼容的规范，否则就违背了制定世界统一编码的初衷。于是它们终于约定好协同工作，且互不干扰，这样就有力地保证了不兼容问题的出现（从Unicode 2.0开始它们已经兼容了，因而个人觉得没有必要纠结它们到底有多大差异，只要了解好Unicode协议即可）。

本小节我们主要讲解Unicode的一些基础知识。

Unicode早期是由Joe Becker，Lee Collins等人于1987年发起研究的，并出现于1988年8月他们为一个系统所写的提议中。虽然当时“Unicode”已经有其他含义（比如一种编程语言），但几位创始人的初衷则是“The name 'Unicode' is intended to suggest a unique, unified, universal encoding”，因而仍然沿用了这个名字。

早期的Unicode只有16bit，在当时看来这已经足够使用了，至少远远超越了ASCII以及其他一些流行编码格式的表达范围。随着Unicode的不断壮大与流行，其他字符编码与Unicode间的mapping也在持续进行，并于1990年底取得阶段性突破。1991年1月3日，Unicode组织成立，同年10月发布了第一版Unicode标准。至今为止，Unicode已经支持超过100种语言以及各种字符。它的表达范围是我们前面提到的0x0-0x10FFFF，即最多可支持1114112个字符。

Unicode的优点是明显的，但也并不是没有缺点。和其他国际规范一样，它也是在不断成长的。比如第一个版本的Unicode是固定的16-bit编码。这样固然很方便，但对有的字符来说是不够用的，而对于像ASCII这种字符来说却又太浪费空间。另外，UCS只是定义了字符对应的“Code Point”，要想在实际生活中取得广泛应用还是有很多问题要解决的。比如这些数值在计算机中如何存储；如果要在网络上面交互应该如何传输等。于是就有了UTF系列规范，如UTF-8、UTF-16及UTF-32。下面以UTF-8为主来讲解。

UTF-8（UCS Transformation Format 8 bit）是一种可变长度的UCS表示方法，又称“万国码”。最初的设计思想来源于ISO 10646中的一个UTF-1编码方式——不过当时这个规范并不让人满意。后来（1992年7月）Unix实验室的Dave Prosser提交了一份新的提议，可以看作UTF-8的原型，但仍然有较大的缺陷。于是到了1992年的8月，Bell实验室的Ken Thompson开始对Dave的方案进行修正与完善，并最终将这一修改于次年的USENIX会议上发表出来，这就是UTF-8。

由于历史因素，各种编码格式比较混乱。为了让读者更清楚地理解这些编码与字符集的关系，下面举个例子来看看UTF所要解决的问题。

比如“你”的Unicode码是0x4F60，我们新建一个文本文件，写入“你”，并把它以ANSI编码保存。根据我们之前的讲解，可以计算出它将占用两个字节的大小，如图16-1所示。

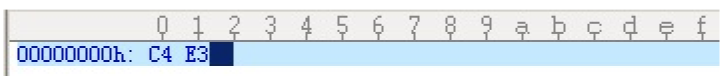

▲图16-1 占用两个字节的大小

如果把它以“Unicode”编码格式保存，如图16-2所示。

▲图16-2 “Unicode”编码格式保存

然后查看这个文件中的二进制，如图16-3所示。

▲图16-3 文件中的二进制

可以看到，编码后的数值是“0xFFFE604F”。

我们再把这个文件保存成UTF-8格式，如图16-4所示。

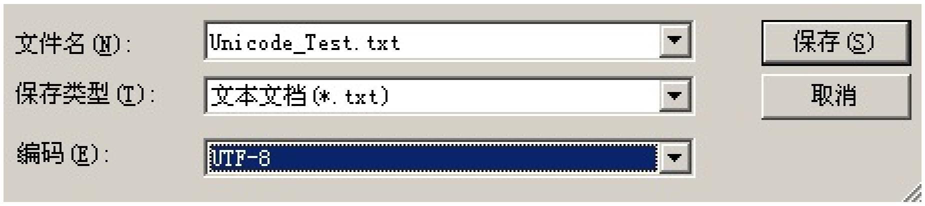

▲图16-4　文件保存成UTF-8格式

此时文件中的编码数值如图16-5所示。

▲图16-5　文件中的编码数值

即“0xEFBBBFE4BDA0”，也就是高达6个字节。

最后我们把它存成Unicode big endian，然后看看它的编码，如图16-6所示。

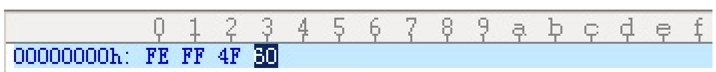

▲图16-6　Unicode big endian编码

从这个例子中，我们至少可以得出以下几点。

- 字节序

“你”的Unicode码是0x4F60，但在存储时是高位在前（大端，Big Endian），还是低位在前呢（小端，Little Endian）？数据在传输过程中必须要考虑这个问题。因为不同的机器很可能采用的字节序是不一样的，如果没有相应的规范来约束，就很可能导致致命问题。在Unicode中，这是由BOM（Byte Order Mark）来保证的。从上面的例子可以看出，头两个字节如果是“0xFFFE”表示小端，0xFEFF则代表大端。

- 编码格式的选择

同一个字符，使用不同编码格式得出的数值是截然不同的。很多人以前可能一直困惑于UCS和UTF系列有什么关联，这就是最好的例子。选择一个好的编码格式无疑可以让整个系统更加高效。

- 编码格式的标志

既然有不同的编码格式可选，那么在对字符进行解码时，自然也要采取对应的编码标准。这就引出了另一个问题：如何知道一个字符采用了什么编码格式？通常我们用Unicode保存文件时，它会在文件开头加上编码标志。如下所示：

ANSI：没有标志

Unicode：0xFFFE(Little Endian)

Unicode Big Endian：0xFEFF

UTF-8：0xEFBBBF

可见，只有UTF-8的标志头占用了超过两个字节的大小。

- 可变长度

我们知道UTF-8是可变长度的，即一个字符占多少字节并不是固定的。那么在一堆编码后的数值中，如何准确界定每个字符的结束位置呢？UTF-8规范中给出了如表16-2所示的转换表。

表16-2　　UTF-8编码规则

Unicode编码（十六进制）	**UTF-8**（二进制）
Zone1：0x000000 - 0x00007F	0xxxxxxx
Zone2：0x000080 -	110xxxxx 10xxxxxx

0x0007FF	
Zone3：0x000800 - 0x00FFFF	1110xxxx 10xxxxxx 10xxxxxx
Zone4：0x010000 - 0x10FFFF	11110xxx 10xxxxxx 10xxxxxx 10xxxxxx

注意

最初的UTF-8协议规定可用bit是可以达到31位以上的，所以部分参考书中给出的UTF-8最长是由6个字节（因为还有一些Leading Byte信息，下面有介绍）来表示的。到了2003年11月，RFC3629限制了这个范围，即只能到0x10FFFF，因而超过四字节的部分就被移除了；而且Zone4所能表达的范围也降低了一部分（Zone4中的x有21个bit位，最大可表达0x1FFFFF，目前只用到0x10FFFF）。

表16-2右边：UTF-8中的x是需要根据具体要表达的Unicode字符进行填写的。比如前面的例子，因为“你”的Unicode码是0x4F60=0100111101100000，属于第Zone3区域，因而转换后的值是：

```
11100100 10111101 10100000=0xE4BDA0
```

这和我们前面所看到的结果是一致的。

从Zone2开始，每个区域的字符都以一个“Leading Byte”起头，它们的高位都是由多个“1”最后跟随“0”来表示的，而且“1”的数量同时也等于该字符占用空间的大小。比如Zone3有3个“1”，它的字符是由3个字节来表示的。“Leading Byte”后面的字节称为“Continuation Bytes”。可以看到，它们都以“10”开头。

因为每个区域的开头标志是不同的，并且相互间不会有歧义，所以

保证了UTF-8表示的字符可以被正确解析。

如图16-7所示（是不是有点像Haffman编码）。

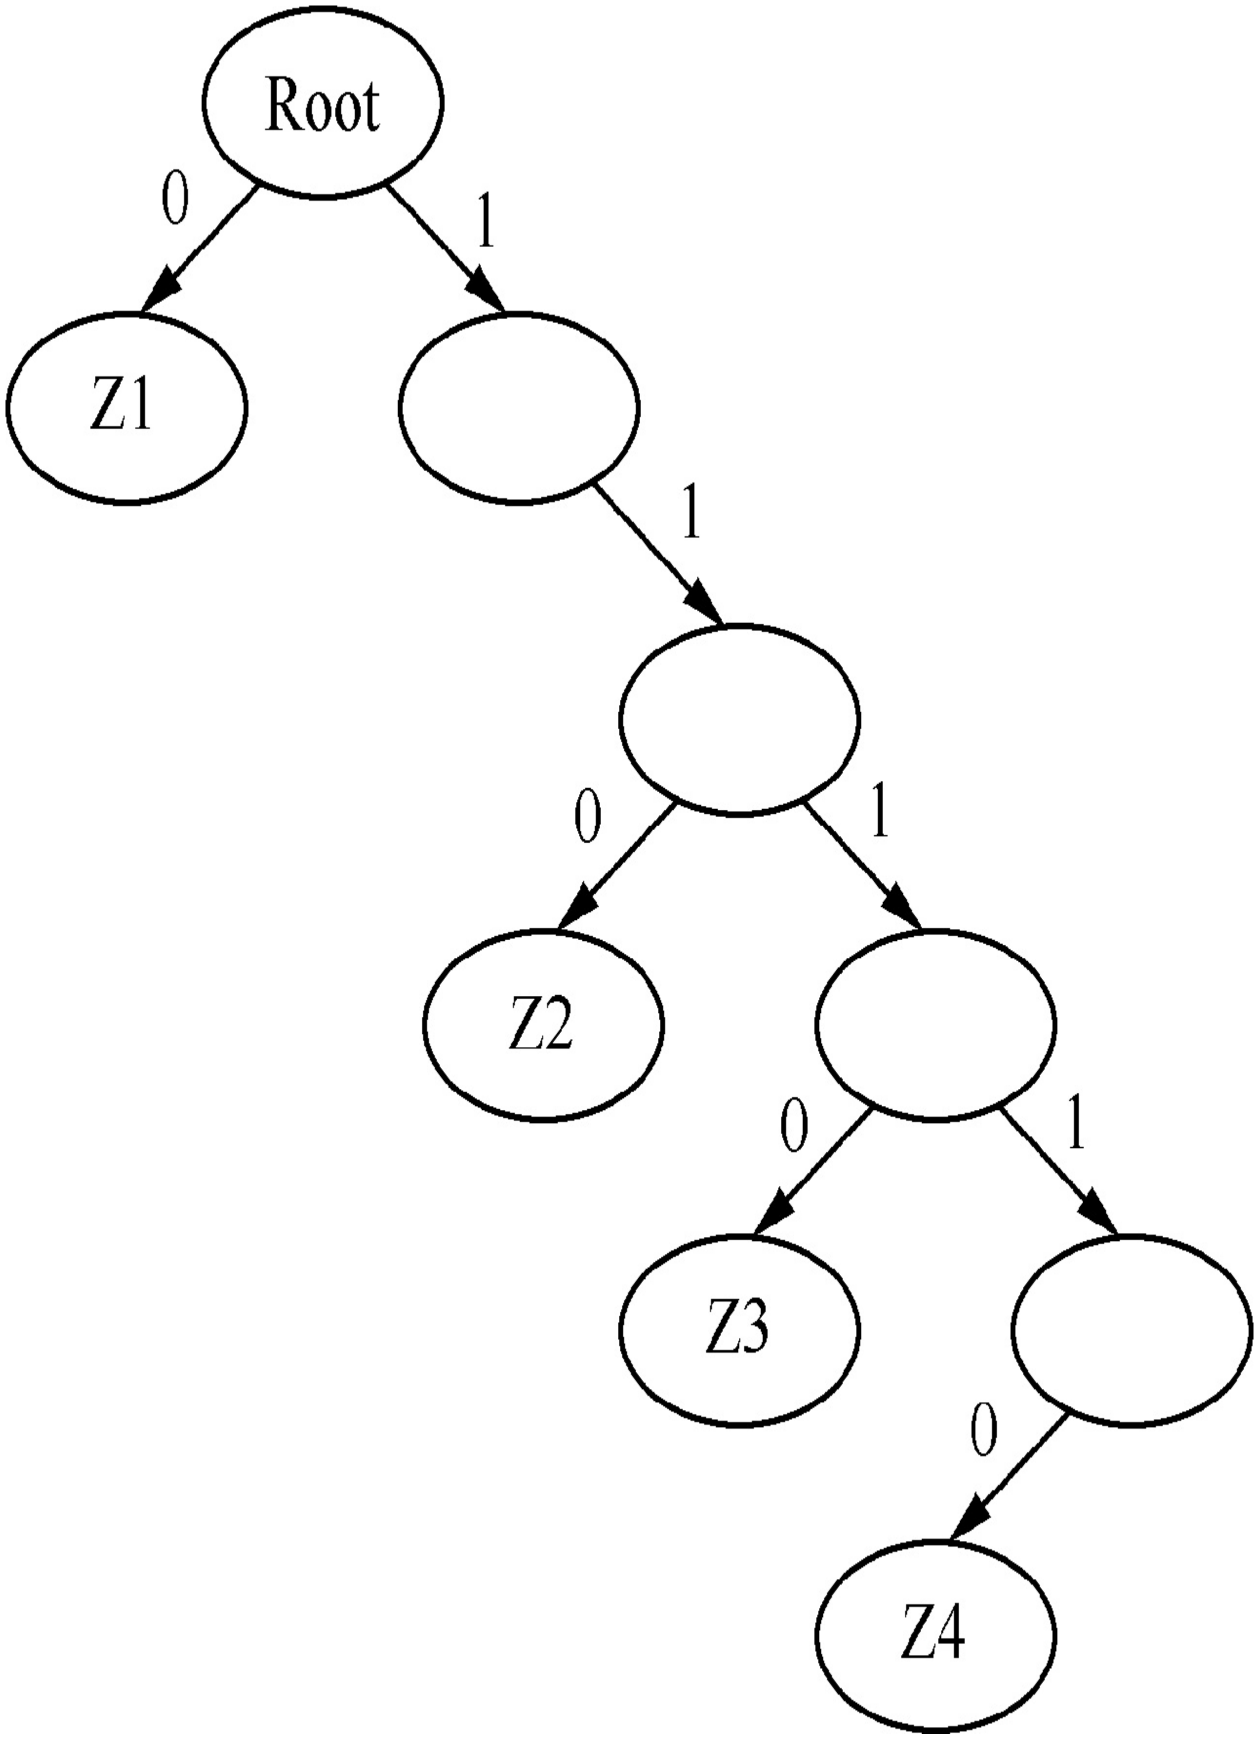
Root
0
1
Z1
1
0
1
Z2
0
1
Z3
0
Z4

▲图16-7 二叉树

这样解码时就可以准确知道这个字符属于哪个区域，也就知道它占用几个字节了。这种特性称为“Self-Synchronizing”，使得我们在处理一个UTF-8码时不需要加入特定的“头信息”就可以正确解析出它所表达的字符——这同时也是它能获得广泛应用的一个重要“法宝”。

顺便说一下，UCS-2是早期的标准，即Unicode编码固定以两个字节表示字符；而UCS-4则是以固定长度的4字节来表示一个字符。UCS-2因为没有办法提供足够的空间容纳越来越多的字符数量，因而逐步被UTF-16所代替。实际上我们平常所见到的Unicode一般都是UTF-16，如前面例子中Windows文本保存时的选项“Unicode”。虽然很容易引起歧义和混淆，但是人们已经养成了习惯，请读者一定要注意区分。

那么，UTF-16为什么能解决UCS-2的缺陷呢？

首先要清楚，UTF-16也是变长的。具体来说，一个字符既可能是两个字节，也可能是4个字节，当然编码范围还是0x000000-0x10FFFF。那么和UTF-8遇到的问题一样，在解析时我们如何知道一个字符到底是用两个字节还是4个字节表示的呢？

UTF-16的基本规则如下。

- 当编码范围在0x0000-0xFFFF时，只占用两个字节。
- 当编码范围超过上述区域，即在0x10000-0x10FFFF时，需要4个字节表示。为了正确区分两字节和四字节编码，需要特别预留出0xD800-0xDFFF作为代理区域（Surrogate）。其中0xD800-0xDBFF是高代理，而0xDC00-0xDFFF是低代理，两个代理组成的4个字节用来表示一个字符：

```
0xD800= 1101100000000000
0xDBFF=1101101111111111
0xDC00=1101110000000000
0xDFFF=1101111111111111
```

解析时，高低代理取出各自低10位，分别作为数值的高低10位，然后加上0x10000，就是此UTF-16所要表达的字符。因为代理所用的数值

范围与前述2个字节表示的字符不重复，因而我们可以判断出此字符到底是2字节还是4字节编码。另外根据上面的描述，使用代理机制所能表示的字符区域是：

0000000000 0000000000（二进制，高低代理末10位）+0x10000-1111 1111 1111 1111 1111(0xFFFFF) +0x10000，也就是：

0x10000-0x10FFFF，这正好符合Unicode所能表达的区域范围。

因为是多字节存储，就会涉及字节序问题，分为UTF-16LE和UTF-16BE，这两种分别对应前面的Unicode和Unicode Big Endian。

16.5　String类型

String类型是我们在编写Java和Android应用程序时使用非常广泛的一个类。它提供了各种便捷的封装接口让开发者轻松处理字符串数据。这个看似不显眼的类实际上是“麻雀虽小，五脏俱全”——因而深入分析String对于我们理解字符编码大有裨益。

先来看看Android官方文档对String的描述：

“An immutable sequence of characters/code units (chars). A String

也就是说，String内部对字符采用的存储格式是UTF-16。具体而言，它有一个char数组类型的全局变量value。

```
private final char[] value;
```

所有对字符串的操作都是以此为基础的。

16.5.1　构建String

String提供了多种构造函数以满足开发者不同方面的需求。比如：

```
String();
String(byte[] data);
String(byte[] data, int high);
String(byte[] data, int offset, int byteCount);
String(byte[] data, int high, int offset, int byteCount);
String(byte[] data, int offset, int byteCount, String charsetName
String(byte[] data, String charsetName);
String(byte[] data, int offset, int byteCount, Charset charset);
String(byte[] data, Charset charset);
String(char[] data);
String(char[] data, int offset, int charCount);
String(String toCopy);
String(StringBuffer stringBuffer);
String(int[] codePoints, int offset, int count);
String(StringBuilder stringBuilder);
```

另外，Android还提供了其他辅助类来创建String对象，如StringBuffer和StringBuilder。

StringBuffer是字符串变量，它生成的对象是可以动态修改的。比如下面这段代码：

```
List<String> values = splitByNullSeperator((String) value);
StringBuffer sb = new StringBuffer();
for(int i=0;i<values.size();i++)
{
    if(i!=0)
    {
         sb.append("\u0000");
    }
    sb.append(values.get(i));
}
return sb.toString();
```

StringBuffer提供了append方法来追加字符串，这个接口也有多种参数形式。比如：

```
append(char[] chars, int start, int length);
append(long l);
append(int i);
append(String string);
```

用于满足不同类型的数据转换成字符串的需求。另外它还提供delete，insert，reverse等常规字符串操作，并可以通过toString将内部数据转换成String类型变量。

StringBuilder所能提供的接口方法和StringBuffer几乎一样，那么两者有什么本质区别呢？我们来分别看看Android对于它们的解释。

StringBuffer：

“A modifiable sequence of characters for use in creating strings, where all accesses are synchronized. This class has mostly been replaced by StringBuilder because this synchronization is rarely useful.”

StringBuilder：

“A modifiable sequence of characters for use in creating strings. This class is intended as a direct replacement of StringBuffer for non-concurrent use; unlike StringBuffer this

class is not synchronized.”

也就是说，StringBuffer是线程安全的，而StringBuilder则是针对单线程的情况设计的，可以理解为StringBuffer的特例。因为StringBuilder没有同步机制，所以如果是多线程的环境，建议使用StringBuffer。不过按照官方的解释，需要同步的情况并不多见，所以鉴于StringBuilder的执行速度更快，它大有取代前者的趋势。开发人员应该根据项目的实际需求来选择合适的辅助类。

16.5.2 String对多种编码的兼容

从前面几个小节的分析，我们知道String是以UTF-16来存储数据的。那么如果原本的字符编码并不是这种格式的，就难免要先进行转换。

String类的构造函数已经考虑到这种情况，比如：

```
public String(byte[] data, int offset, int byteCount, Charset cha
```

参数中data是原始数据，Charset是指数据的编码格式。

Charset用于Unicode字符与byte字节流之间的转换。具体来说：

- Decode

  这是Charset的基础工作，因而要求必须支持。

- Encode

  部分Charset还支持编码工作，可以通过canEncode()来查询。

Android系统内置了以下几种Charset。

ISO-8859-1：可以参照前面的介绍

US-ASCII：ASCII编码

UTF-16

UTF-16BE

UTF-16LE

UTF-8：UTF的这几种编码格式在前一个小节也都有详细分析，不再赘述

接下来我们通过上述String构造函数的内部实现来进一步理解这些编码间的转换过程：

```
   public String(byte[] data, int offset, int byteCount, Charset
        if ((offset | byteCount) < 0 || byteCount > data.length -
            throw failedBoundsCheck(data.length, offset, byteCoun
        }
        String canonicalCharsetName = charset.name();//编码格式
        if (canonicalCharsetName.equals("UTF-8")) {
            …//后面详细分析
        } else if (canonicalCharsetName.equals("ISO-8859-1")) {
            …//代码略
        } else if (canonicalCharsetName.equals("US-ASCII")) {
            …//代码略
        } else {
            CharBuffer cb = charset.decode(ByteBuffer.wrap(data,
            this.offset = 0;
            this.count = cb.length();
            if (count > 0) {
                this.value = new char[count];
                System.arraycopy(cb.array(), 0, value, 0, count);
            } else {
                this.value = EmptyArray.CHAR;
            }
        }
    }
```

整个函数分为两部分，如果原始数据是UTF-8，ISO-8859-1或者US-ASCII中的任何一种，都会直接进行转换处理；否则调用charset变量本身的decode方法进行解码。

UTF-8是这几种处理中最复杂的一个，我们来具体分析下：

```
byte[] d = data;
char[] v = new char[byteCount];
int idx = offset;
int last = offset + byteCount;
```

```
int s = 0;
```

上面几个变量，d是原始数据，v是将要在String中存储的UTF-16的编码结果，idx和last分别是原始数据中被处理部分的起止位置。

由于UTF-8是可变字节的编码方式，因而最为关键的是确认一个字符的结束位置。下面的主循环将逐一处理data中从[0,last]的字节序列，并依据前一小节讲解的UTF-8几个区域标志码确定每个字符的字长大小。为了方便读者阅读，我们再把这个表列出来，如表16-3所示。

表16-3　确定每个字符的字长大小

Unicode编码（十六进制）	**UTF-8**（二进制）
Zone1：0x000000 - 0x00007F	0xxxxxxx
Zone2：0x000080 - 0x0007FF	110xxxxx 10xxxxxx
Zone3：0x000800 - 0x00FFFF	1110xxxx 10xxxxxx 10xxxxxx
Zone4：0x010000 - 0x10FFFF	11110xxx 10xxxxxx 10xxxxxx 10xxxxxx

主循环代码如下：

```
outer:
            while (idx < last) {
                byte b0 = d[idx++];
                if ((b0 & 0x80) == 0) {
                    int val = b0 & 0xff;
                    v[s++] = (char) val;
```

当字节最高位为0时，说明它是ASCII码(表中的Zone1)，因而只占一个字节。处理时只要将这个字节存入v变量中即可：

```
} else if (((b0 & 0xe0) == 0xc0) || ((b0 & 0xf0) == 0xe0) ||
    ((b0 & 0xf8) == 0xf0) || ((b0 & 0xfc) == 0xf8) || ((b0 & 0xfe
```

注意

上面的b0是变量，不是十六进制的b0。

0xe0=11100000，0xc0=11000000，当第一个等号成立时，表示Zone2。

0xf0=11110000，0xe0=11100000，当第二个等号成立时，表示Zone3。

0xf8=11111000，0xf0=11110000，当第三个等号成立时，表示Zone4。

后面的几个等号分别表示Zone5和Zone6，前一个小节我们已经解释过这是针对早期版本的处理，因而可以跳过：

```
int utfCount = 1;
if ((b0 & 0xf0) == 0xe0) utfCount = 2;
else if ((b0 & 0xf8) == 0xf0) utfCount = 3;
else if ((b0 & 0xfc) == 0xf8) utfCount = 4;
else if ((b0 & 0xfe) == 0xfc) utfCount = 5;
```

这里的utfCount表示“Continuation Bytes”的个数，因为前面idx已经自增了，而“Leading Byte”用b0来表示：

```
if (idx + utfCount > last) {
    v[s++] = REPLACEMENT_CHAR;
    break;
}
```

当idx+utfCount超过数据边界时，说明数据有错误，跳出循环。REPLACEMENT_CHAR = (char) 0xfffd：

```
int val = b0 & (0x1f >> (utfCount - 1));
```

```
for (int i = 0; i < utfCount; i++) {
    byte b = d[idx++];
    if ((b & 0xC0) != 0x80) {
        v[s++] = REPLACEMENT_CHAR;
        idx--;
        continue outer;
    }
    val <<= 6;
    val |= b & 0x3f;
}
```

上面这段代码用于取出UTF-8中的数据部分。

- 首先，取出Leading Byte即b0中的有效数据。
- 根据utfCount的数量，逐一取出剩余Continuation Bytes中的有效数据。因为这些字节的首两位必须是10，所以b&0xC0等于0x80，否则数据无效。最后将它们统一拼接成UTF-16值。

上面的计算还没有考虑数值超过两个字节的情况（因为val是int类型，足够容纳所有范围的数值），所以接下来还要进一步判断：

```
if ((utfCount != 2) && (val >= 0xD800) && (val <= 0xDFFF)) {
    v[s++] = REPLACEMENT_CHAR;
    continue;
}
```

假如数值大小超过两个字节，那么必须使用代理：

```
if (val > 0x10FFFF) {
    v[s++] = REPLACEMENT_CHAR;
    continue;
}
```

先检查val是否大于Unicode所能表达的范围，即0x10FFFF。

然后对Zone4部分采用代理模式进行编码：

```
    if (val < 0x10000) {
        v[s++] = (char) val;
    } else {
        int x = val & 0xffff;
        int u = (val >> 16) & 0x1f;
        int w = (u - 1) & 0xffff;
```

```
            int hi = 0xd800 | (w << 6) | (x >> 10);
            int lo = 0xdc00 | (x & 0x3ff);
            v[s++] = (char) hi;
            v[s++] = (char) lo;
        }
    } else {
        // Illegal values 0x8*, 0x9*, 0xa*, 0xb*, 0xfd-0xff
        v[s++] = REPLACEMENT_CHAR;
    }
}
```

最后，把上述处理结果存入String的value数组中。因为byteCount是用户通过传参进来的，如果计算出的结果和这个参数值一致，那么可以直接保存结果，否则还需要重新申请合适的空间进行复制：

```
if (s == byteCount) {
    this.offset = 0;
    this.value = v;
    this.count = s;
} else {
    this.offset = 0;
    this.value = new char[s];//重新申请空间
    this.count = s;
    System.arraycopy(v, 0, value, 0, s);//复制
}
```

其他几种编码比较简单，读者可以自行阅读理解。

第17章

Android和OpenGL ES

在本书显示系统的学习中，读者应该已经发现无论是Surface、SurfaceFlinger还是View体系，都直接或间接地以OpenGL ES为设计核心。

一方面，OpenGL ES在Android系统中起到了重要作用；而另一方面，并不是所有读者都深谙OpenGL ES（根据Android项目经验，不少开发者在理解显示系统时的最大阻力就是缺乏OpenGL基础—鉴于此，本章将有目的性地引导读者学习与Android设计相关的那部分OpenGL ES知识。

OpenGL（Open Graphics Library）最初是由SGI（Silicon Graphics Inc.）公司开发的。发展到今天，它已经占据了包括虚拟现实、CAD、能源、游戏研发等多个行业领域，成为名副其实的跨语言、跨平台的2D/3D图形处理“王者”。

OpenGL的管理者为Khronos组织，这是一个2000年成立的，由ATI、Intel、NVIDIA、SGI、SUN等行业内领先企业发起的非营利性联盟。目前其旗下已经分为若干个工作组，具体如下所列。

- OpenGL：跨平台的计算接口。
- OpenGL SC：应用于对安全有较高需求的OpenGL ES市场。
- OpenKODE：提供了访问文件系统、网络之类的操作系统资源的接口。
- OpenGL ES：本章节的主角。它是专门面向于嵌入式领域的。

- EGL：它是Rendering API（比如OpenGL ES）和本地窗口平台之间的一个接口层。
- OpenGL VG：用于2D向量图的处理加速。
- OpenML：用于数字媒体的捕获、传输、处理、显示和同步等。
- WebGL：浏览器中绑定的OpenGL ES的一个JavaScript脚本。
- Vision：用于图形显示的硬件加速。

OpenGL的运行对设备要求较高，很难被直接应用在CPU和内存资源匮乏、用电量需要严格控制甚至没有浮点数硬件协助的嵌入式设备上——于是OpenGL ES应运而生。

OpenGL ES（OpenGL for Embedded Systems）是由Khronos推出的，专门面向嵌入式系统的OpenGL API子集。目前已经成功应用于PDA、汽车电子、手机等一系列电子产品中，Android系统也是从版本早期就开始支持这一图形库。它不仅可以为Android开发者提供3D图形的实现，也同样广泛应用于2D的视频与图像处理。其强大的渲染和特效处理功能，可以无限扩展应用开发者的想象力。

OpenGL ES相较于OpenGL，在设计上至少需要考虑以下几点。

- 尽量精简实现方式。比如在OpenGL中可以找到一种问题的N个解法，而在OpenGL ES版本中可能只被允许使用固定的一种。
- 保证兼容性。不仅是OpenGLES版本间的兼容，也要考虑OpenGL ES与OpenGL主版本间的兼容。
- 不断改进。特别是根据硬件的升级来完善自身。

到目前为止，Android系统支持OpenGL ES 1.0、1.1（从Android 1.0开始），2.0（从Android 2.2，Level 8开始），以及3.0（Android 4.3，API level 18开始）的API。那么，这几个版本有什么区别呢？

根据Khronos的解释，1.X版本的OpenGL ES是“For fixed function hardware”，而2.X则是“For programmable hardware”，因而它们最大的差异就是后者属于“programmable”。可编程的特性可以极大地扩展图形硬件的功能以及灵活性。3.X版本加入了更多新特性，如着色语言的完善、支持更多缓冲区对象、支持几何体实例化、统一的纹理压缩格式等。这些新特性不但可以让3D画面更加流畅和绚丽，

而且研发者的工作也相对简单了。不过这些新功能并不影响我们分析Android的内部原理，有兴趣的读者可以自行参阅资料。

相对于其他API而言，Google针对OpenGL ES 的官方指南还不是很完善——有很多接口甚至只有一个声明体而没有任何释义。这对初学者可能会造成一定的困难，为此我们将先从图形处理的基础知识讲起，再逐步过渡到OpenGL。

17.1 3D图形学基础

17.1.1 计算机3D图形

什么是计算机3D图形？

3D这个词出现的频率如此之高，以至于很多时候我们会对它“熟视无睹”——但真正让我们来解释，相信并不是所有人都能答得上来。从字面意思来看，它是指Three-Dimensional，即三维的图形。一般情况下，即指长、宽和深度（高度）3个维度。

随着计算机系统的不断发展，计算机输出结果的方式从早期的纸质打印到后来的CRT、液晶等发生了翻天覆地的变化。但有一点却是始终不变的，即它们实际上都是平面二维的。换句话说，即便我们所说的计算机中的3D图形，也只是在2D屏幕上创造出来的立体效果。

那么问题的关键就在于，如何才能在二维的界面上制造出三维的“错觉”。

要解答这个问题，我们有必要先分析下人类是如何感知到3D物体的，如图17-1所示。

从简图可以知道：

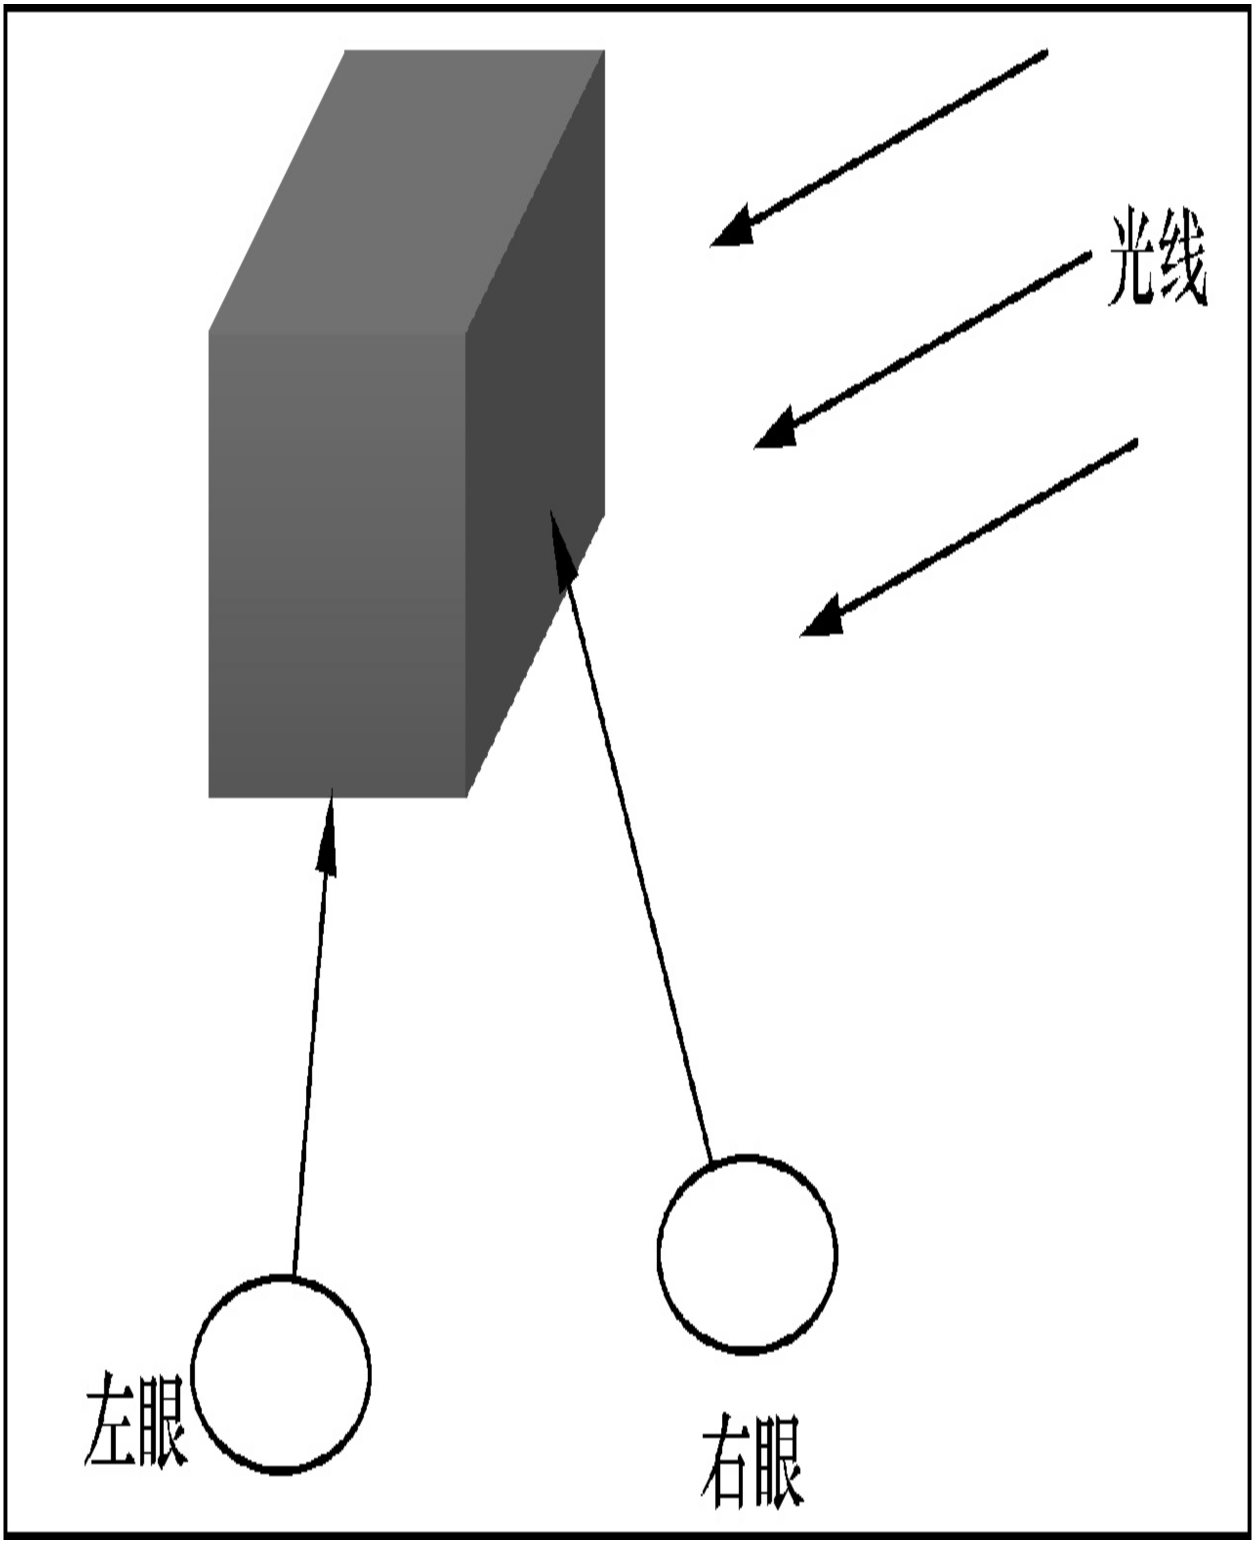

▲图17-1 人眼感知3D物体

从简图可以知道：

- 光线是感知物体的基础，在黑暗的环境下人眼是无法看清东西的。
- 人体有左右两个眼球，并且两者之间有一定间距，这样它们可以从不同的角度来获取到一个物体的信息。这些信息在传输到两个眼球时是有略微差别的，再经过大脑的处理后，便形成了物体的三维效果。看到这里有的读者可能会想，如果是这样，那么我闭上一只眼睛看到的物体不是变成了2D吗？答案当然是否定的。因为虽然这时只有一只眼球在接收信息，但它还是可以通过其他信息来判断物体是否具有深度（第三维度）——比如近的对象看起来会比较大，而远的物体看起来小，还有光影效果、颜色变化等都可以为眼球产生三维感觉提供信息。这同时也是我们在计算机图形中可以创造人工3D效果的基础之一。

还有一点可以肯定的是，随着人闭上其中一只眼睛，辨识物体深度的能力将大大降低。读者可以做个试验，将两只圆珠笔放在眼前，然后闭上其中一只眼，这时如果想把两只笔的笔头碰在一起是不是困难了很多？这是因为仅靠一只眼，已经很难通过左右两眼的“图像差”来获知物体的深度距离了。

对于显示在计算机屏幕上的图像来说，它没有办法从不同的角度为两个眼球提供有差异的图像（办法其实是有的，如现在非常流行的3D电影，就是通过把影片中两幅叠加的图像，经由3D眼镜分离出来而产生立体特效。但是这种方式显然不适用于计算机场合），因而必须要有其他的人工方式。除了上述提到的光影效果等一系列方法外，还有一种很简单的方式是我们初中学习几何时就用过的——透视，如图17-2和图17-3所示。

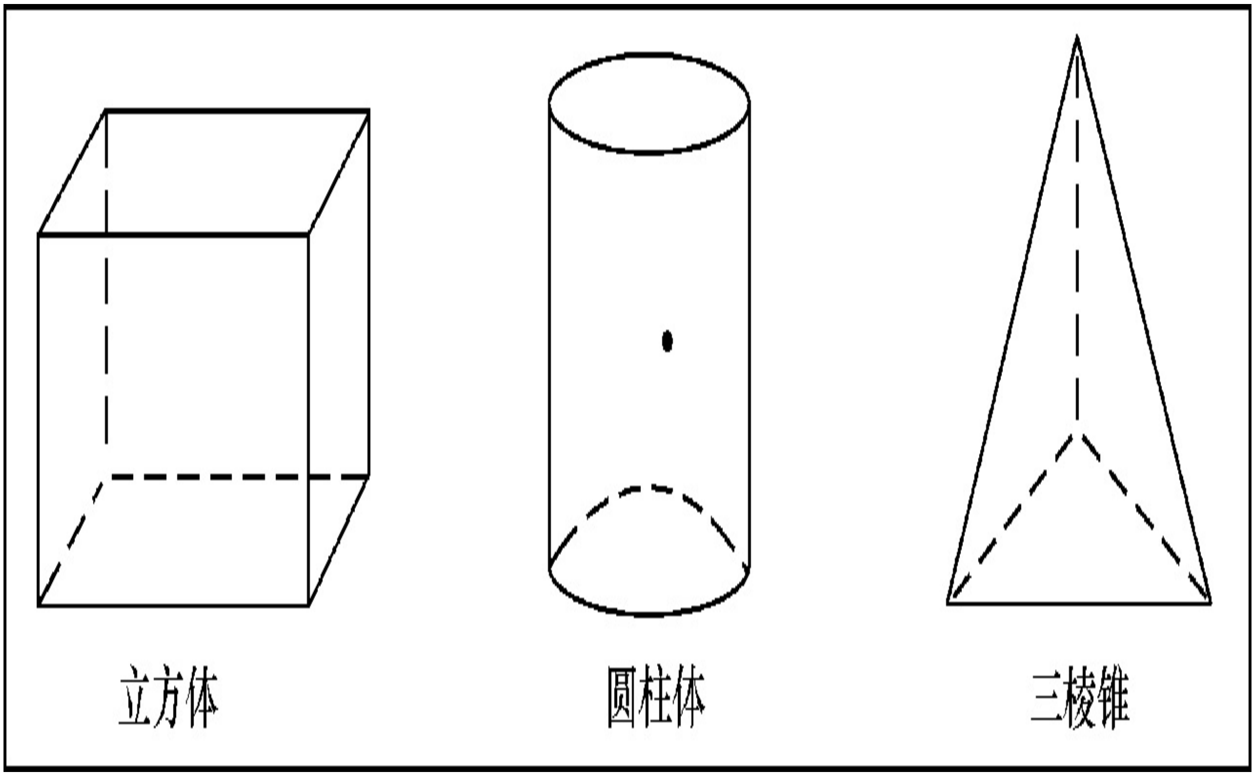

▲图17-2 利用透视产生立体效果

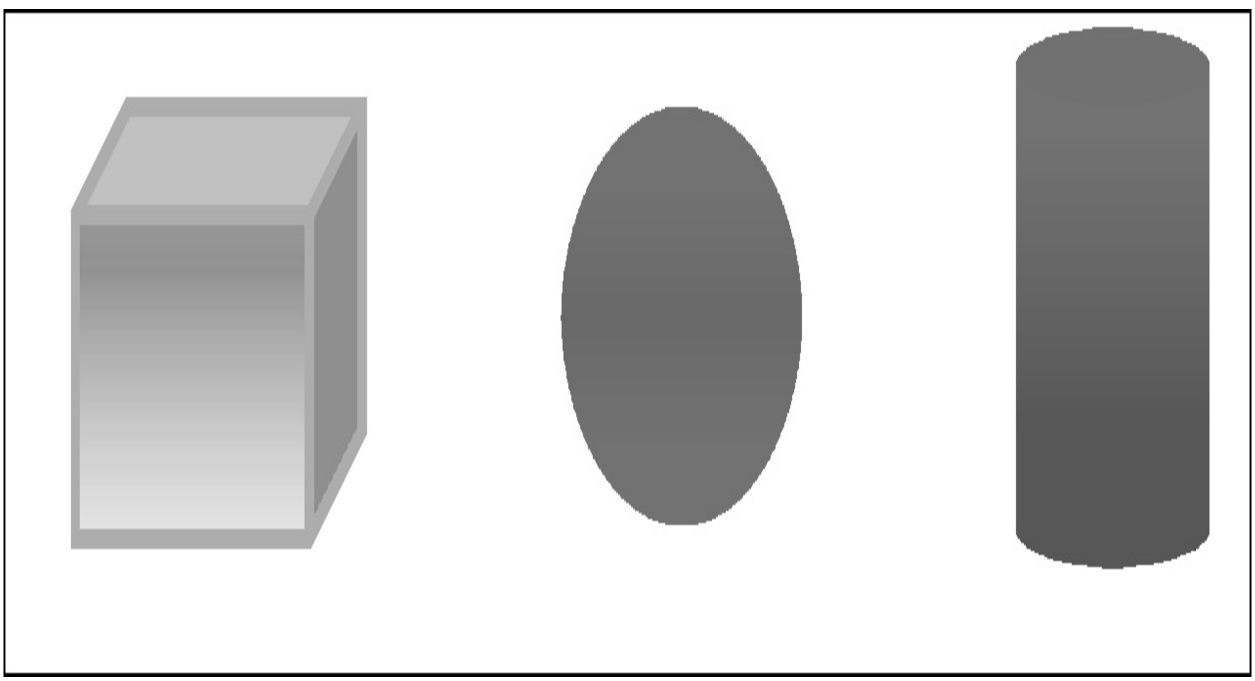

▲图17-3 利用光影产生三维效果

通过以上两种效果，读者是否感知到了立体图形？这样我们的目的就达到了。

17.1.2 图形管线

在计算机图形处理中，任何复杂的图像都可以由固定数量的基础几何元素，通过一系列手法逐步加工出来。以OpenGL ES为例，它只支持3种基本的几何元素，即：

- 点（Point）；
- 线段（Line）；
- 三角形（Triangle）。

图形管线（Graphics Pipeline或者Rendering Pipeline）通常是指图形硬件设备（GPU）支持的渲染流程。简单地说，它是以3D数据为输入（比如游戏场景的描述），并最终输出2D光栅图形的一种流水线处理过程。前面已经说过，虽然从理论上来说是三维图形，但实际上绝大多数用户都是在二维的终端显示屏上（比如PC的显示器）观看3D效果的，因而就必然有3D2D的转化过程。而之所以说是流水线，因为它的处理过程符合工厂中产品的流水线生产顺序。当今最流行的两种3D接口，即OpenGL和Direct3D都有自己定义的管线，本小节我们只分析与OpenGL相关的实现。

图17-4展示了1.X版本的OpenGL ES的Pipeline。

2.X版本的Pipeline有一些差异，如图17-5所示。

从这两个图的对比中，我们可以知道：

- 2.X系列的管线模型更加精简

因为它支持可编程的方式，这样原本ES 1.1中一些用Shader Program实现的功能就被去掉了；同时降低了硬件的成本以及能量消耗。

- 增加了OpenGL ES Shading Language

它和OpenGL中的Shading编程语言基本上一致，只不过针对嵌入式

系统做了些优化。

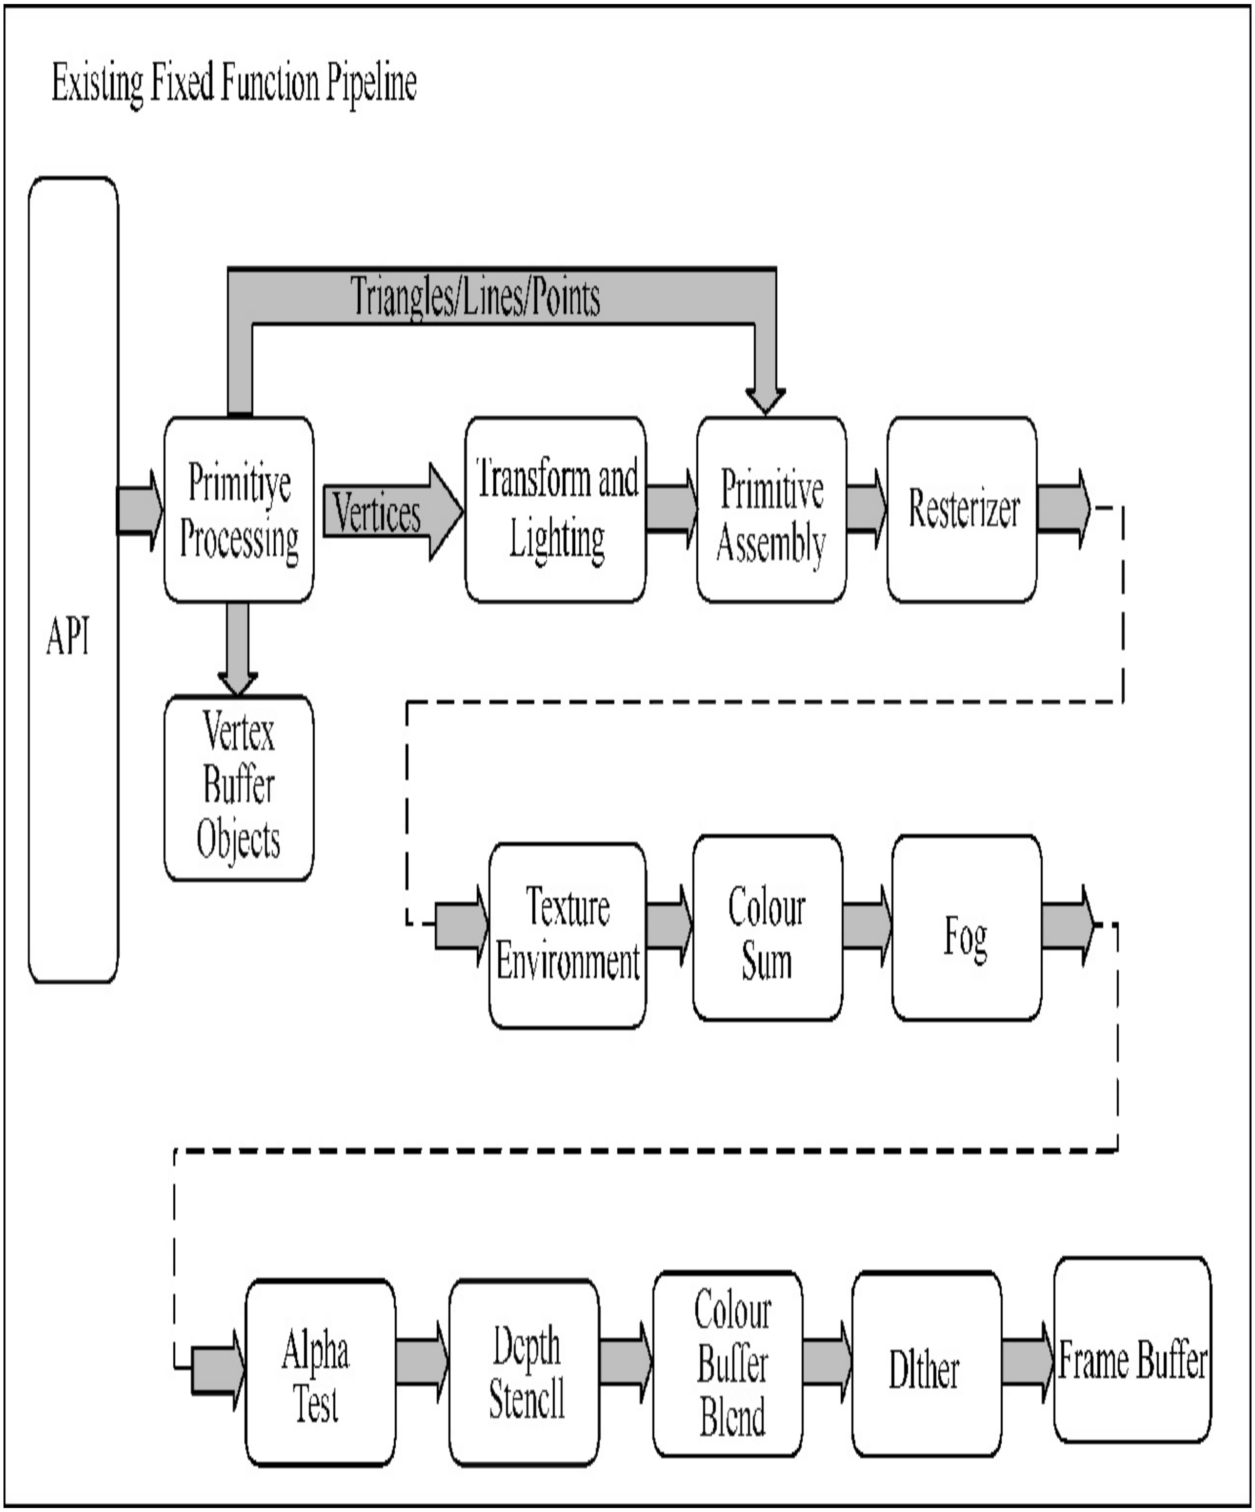

▲图17-4 OpenGL ES 1.X Pipeline （注：引用自http://www.khronos.org/opengles/2_X/。）

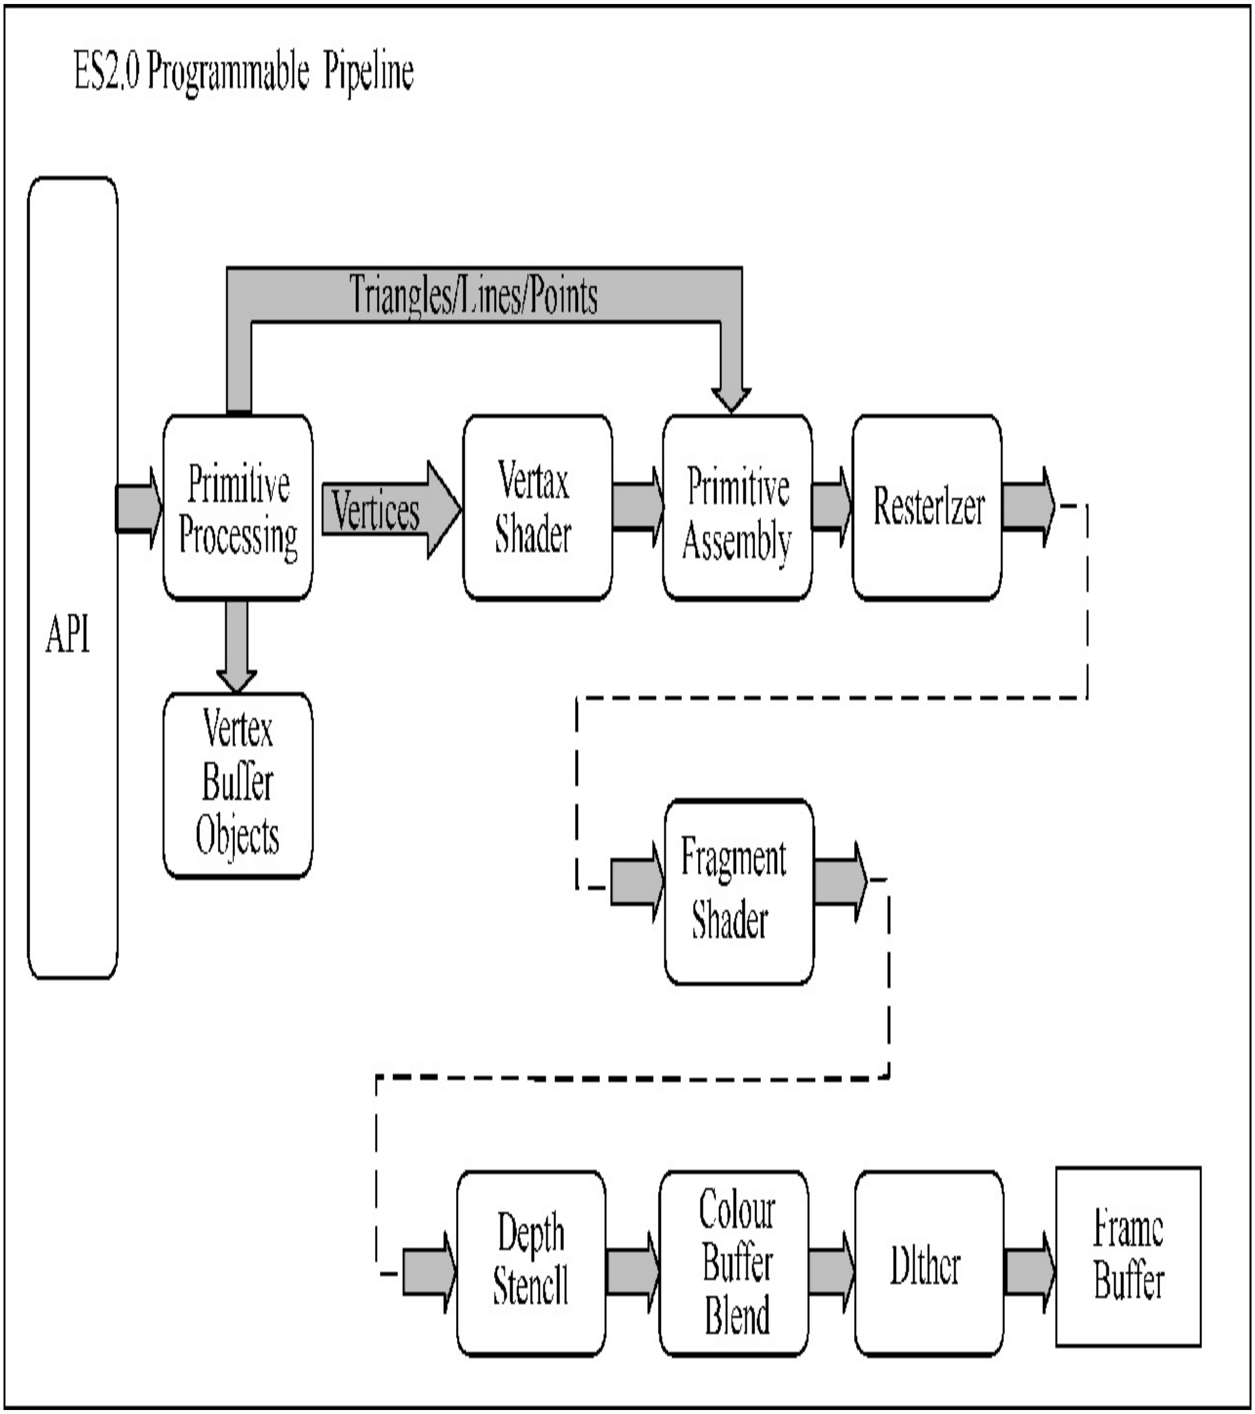

▲图17-5 OpenGL ES 1.X Pipeline （注：引用自http://www.khronos.org/opengles/2_X/。）

下面的链接是了解各系列OpenGL ES中API的重要文档，建议读者认真阅读一下。

OpenGL ES 3.0.2 Specification:

http://www.khronos.org/registry/gles/specs/3.0/es_spec_3.0.

OpenGL ES 2.0.25 Full Specification:

http://www.khronos.org/registry/gles/specs/2.0/es_full_spec

OpenGL ES 1.1.12 Full Specification:

http://www.khronos.org/registry/gles/specs/1.1/es_full_spec

EGL 1.4 Specification:

http://www.khronos.org/registry/egl/specs/eglspec.1.4.2011(

EGL 1.4 Header File:

http://www.khronos.org/registry/egl/api/EGL/egl.h

EGL 1.4 Extension Header File:

http://www.khronos.org/registry/egl/api/EGL/eglext.h

17.2 Android中的OpenGL ES简介

代码路径：

- frameworks\base\opengl

Java层SDK。

- frameworks\base\core\jni

JNI层实现。

- frameworks\native\opengl

C++代码实现。

- external\mesa3d

Mesa 3D引擎库。

我们知道，Android系统中采用了OpenGL ES。具体实现中包括如下几个部分。

- OpenGL ES

OpenGL本身只是协议规范，而不是软件源码库，这一点要特别注意。

- EGL

读者EGL可能比较陌生，它是“Khronos Native Platform Graphics Interface”的缩写，即介于本地窗口系统和Rendering API（这里是指OpenGL ES）之间的一层接口。EGL主要负责图形环境管理、surface/buffer绑定、渲染同步等。本节接下来还会有详细的解析。

下面这个网址有EGL官方的一些介绍资料，建议读者先阅读下。

http://cn.khronos.org/egl。

- Mesa 3D

Mesa是兼容OpenGL协议的3D图形处理软件库；同时还是开放原始代码的（不过是基于MIT License），如图17-6所示。

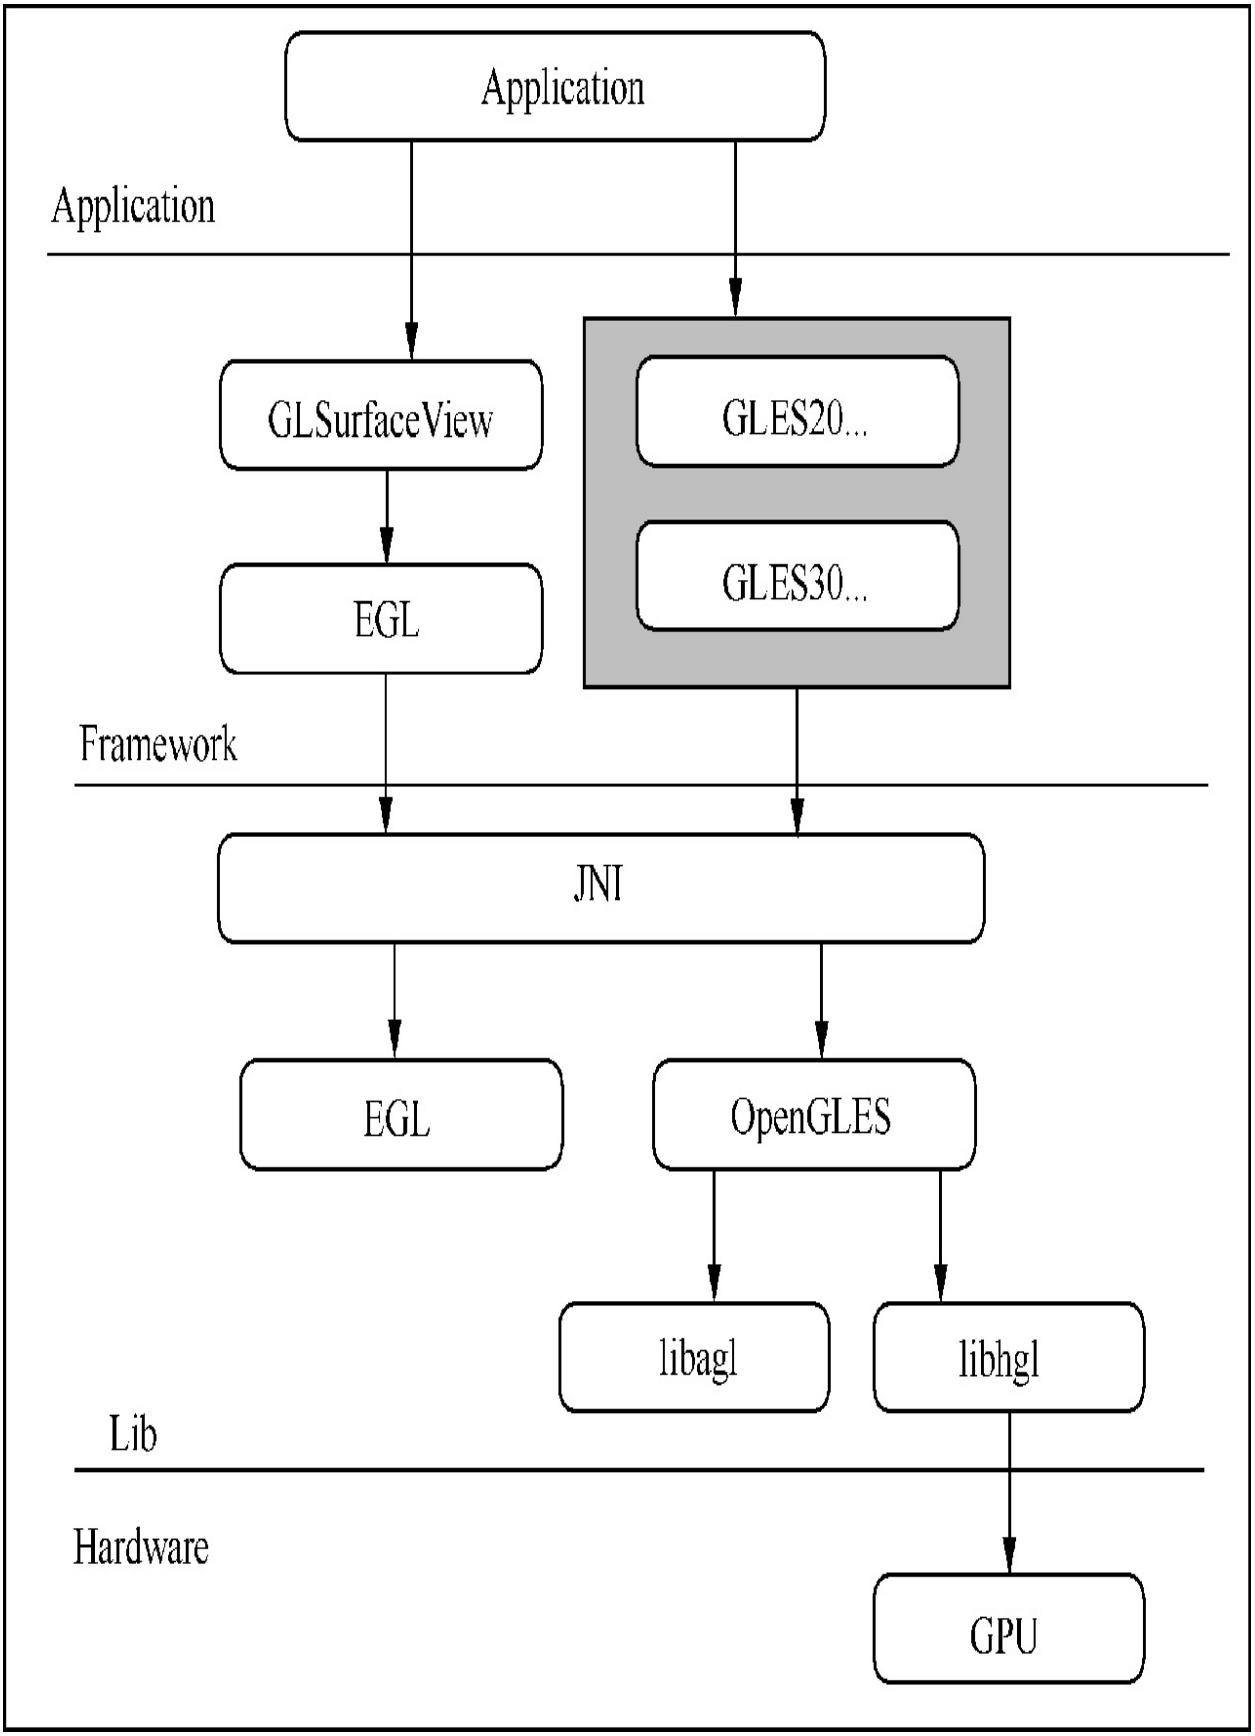

Application
Application
GLSurfaceView
GLES20...
GLES30...
EGL
Framework
JNI
EGL
OpenGLES
libagl
libhgl
Lib
Hardware
GPU

▲图17-6 Android中的OpenGL ES框架简图

下面打个比方，以帮助读者理清这些模块之间的关系。OpenGL ES就像打印机的标准一样，如它规定了printline（point1，point2）这个接口是用于打印一条从point1到point2的线段。假设打印机厂商（HP、DELL、EPSON等）接受了这一协议，那么它们就需要在自己的设备中引入这样的实现。如此一来，无论是哪款遵循协议规定的打印机，只要向它发送printline命令，最终得出的结果都应该是一样的。Mesa就是“打印机厂商”，并且它所生产的“设备”是完全开源的。

除了核心的OpenGL API外，各厂商（vendors）、厂商组织（groups of vendors）和ARB（Architecture Review Board）也可以扩展和定义额外的API——并需要加上相应的标志。比如GL_ARB_multitexture由ARB提出，GL_SGI_color_matrix来自于SGI，而GL_NV_texgen_emboss则出自nVidia之手。更多细节可以参见：http://www.opengl.org/registry/。

17.3 图形渲染API——EGL

17.3.1 EGL与OpenGL ES

EGL与OpenGLES

如图17-7所示。

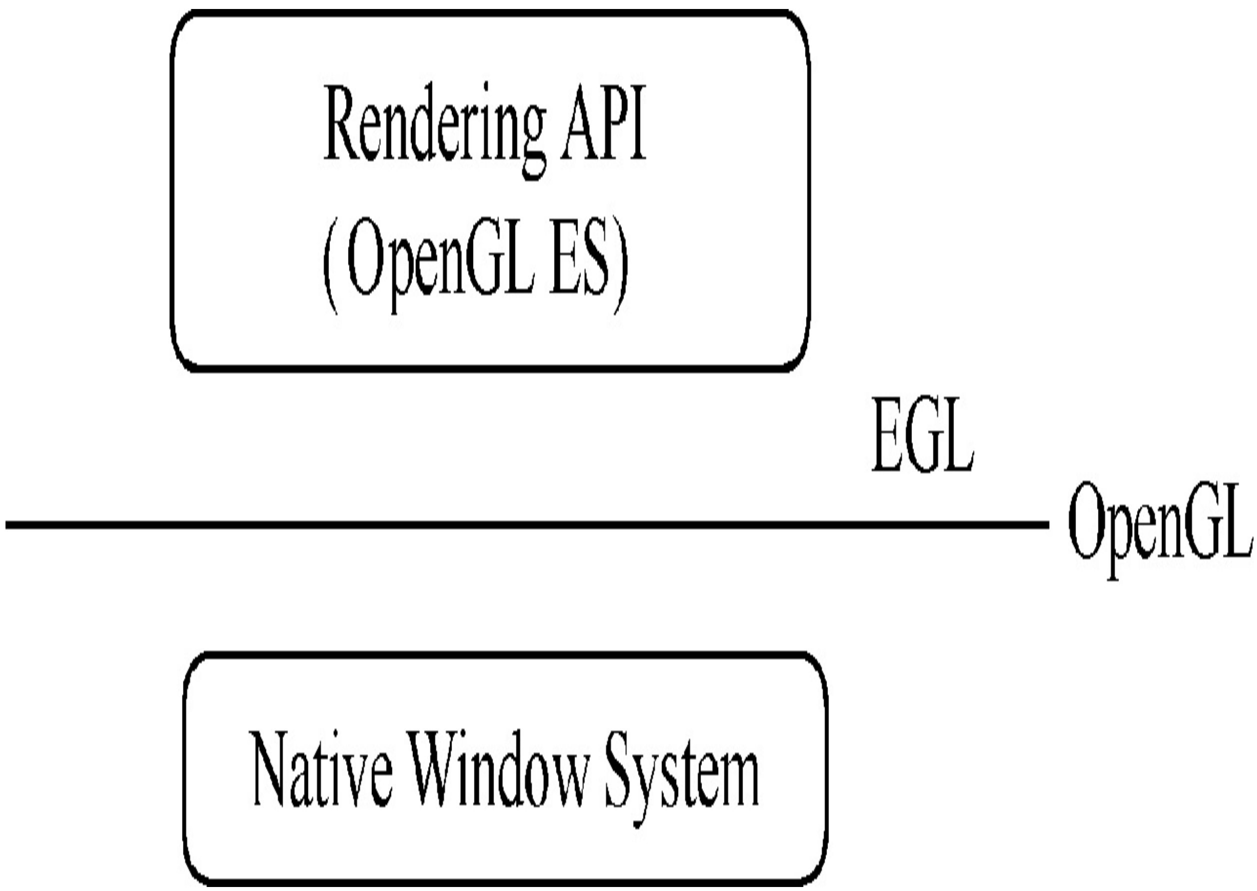

▲图17-7 EGL与OpenGL

前面已经提到过EGL，它是图形渲染API（比如OpenGL ES）和本地窗口系统间的一层接口。主要提供了如下功能：

- 创建rendering surfaces

Surface的字面意思是“表面”，通俗地讲就是能够承载图形的介

质，如一张“画纸”。只有成功申请到Surface，应用程序才能真正“作图”到屏幕上。

- 创造图形环境（graphics context）

OpenGL ES说白了就是一个Pipeline，因而它需要状态管理——这就是context的主要工作：

- 同步应用程序和本地平台渲染API;
- 提供了对显示设备的访问;
- 提供了对渲染配置的管理（见下一小节）。

简而言之，EGL可以有效保证OpenGL ES的平台独立性，因而接下来将详细讲解如何使用EGL来为OpenGL ES提供服务。考虑到如果单纯从理论的角度来分析，读者可能会感觉抽象，所以我们还是结合代码范例来讲解。

17.3.2 egl.cfg

图形渲染所采用的方式（硬件、软件）是在系统启动后动态确定的（源码文件是frameworks/ native/openl/libs/egl/Loader.cpp）——如果是在硬件加速的情况下，系统首先要加载相应的libhgl库；否则加载libagl来由CPU进行图形处理。

具体来说，系统是根据egl.cfg文件的解析结果来选择图形渲染方式的。流程如下：

- egl.cfg文件是否存在

这个文件通常保存在源码工程的/device/[Manufacture]目录下，然后经过编译被烧写到设备中的如下位置：

```
/system/lib/egl/egl.cfg
```

假如此文件不存在，说明硬件不支持图形渲染加速，因而只能通过加载软件库libagl来完成图形处理工作。

- egl.cfg文件存在的情况下

如果egl.cfg存在，我们需要先解析这个文件。它的语法格式如下：

```
#<DisplayNumber><HW/SW><Lib_Name>
0 1 mali
```

其中第一个数字表示显示屏编号。Android系统理论上支持多个显示设备，但到目前为止还只能支持一个，所以这个数值必须为0。

第二个数字指明是硬件库（1）还是软件库（0）。比如上面这个例子中采用的是硬件加速，因而值为1。

第三个参数是库的名称。我们需要将对应的实现库放在/system/lib/egl或者/vendor/lib/egl/目录下，而且库的名称必须以如下格式进行命名：

```
libEGL_<Lib_Name>.so
libGLES_<Lib_Name>.so
libGLESv1_CM_<Lib_Name>.so
libGLESv2_<Lib_Name>.so
```

egl.cfg中可以同时配置多个库。要特别注意优先级是随着行顺序而逐步递减的，因而开发者应该把最佳实现库放在最上面。比如：

```
0 1 mali    #硬件加速，采用ARM的mali系列GPU
0 0 android #默认配置
```

在原生态的Android版本中，默认情况下的渲染库有4个，如图17-8所示。

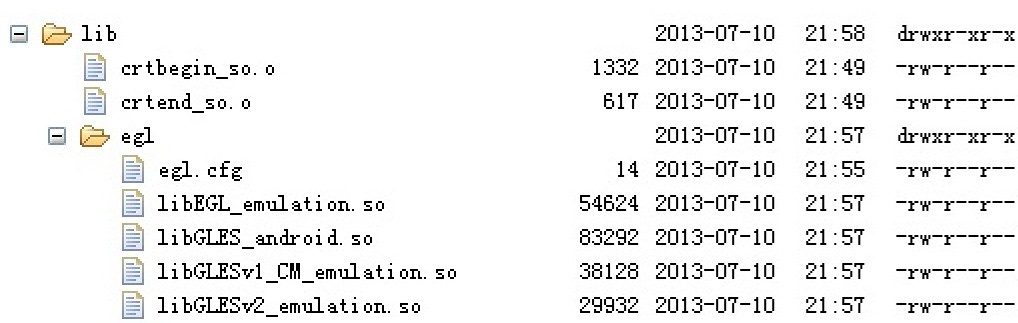

▲图17-8 默认情况下的渲染库

- OpenGL函数的执行

通过上一步的选择后，系统已经能确认出是采用硬件还是软件来做图形渲染了，并同步加载正确的实现库。这样OpenGL函数在后续执行过程中就知道应该跳转到libagl还是libhgl了。

Egl函数的调用流程如下：

egl_init_drivers@Egl.cpp→egl_init_drivers_locked@Egl.cpp→载egl.cfg）→open@Loader.cpp→ load_driver @Loader.cpp（加载对应的open gl库），如图17-9所示。

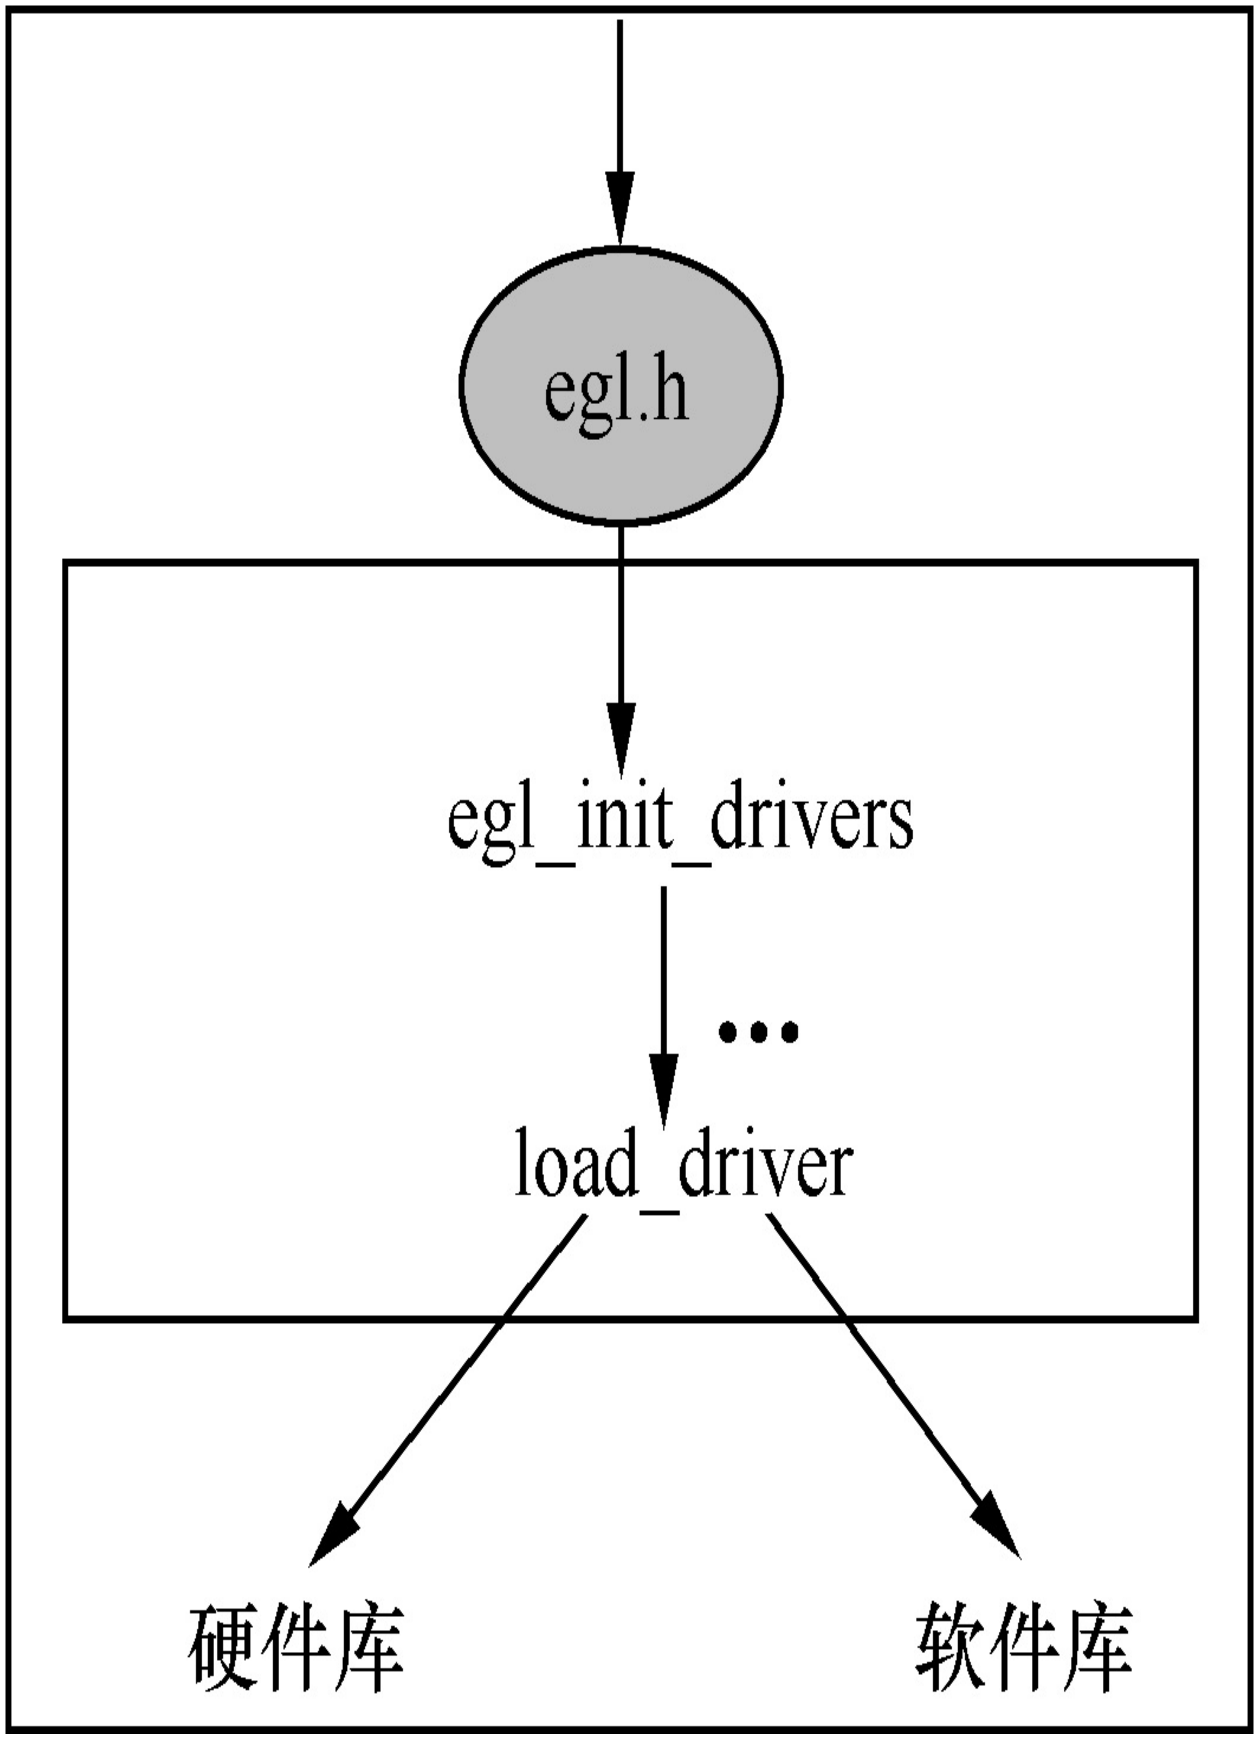
egl.h
egl_init_drivers
...
load_driver
硬件库
软件库

▲图17-9 egl加载库的流程图

头文件egl.h提供了一系列面向外界的接口。比如：

```
EGLAPI EGLDisplay EGLAPIENTRY eglGetDisplay(EGLNativeDisplayType
EGLAPI EGLBoolean EGLAPIENTRY eglInitialize(EGLDisplay dpy, EGLin
EGLint *minor);
EGLAPI EGLBoolean EGLAPIENTRY eglTerminate(EGLDisplay dpy);
```

当调用其中任何接口时，egl都会自动加载OpenGL的实现库——通过解析egl.cfg文件来判断是加载软件还是硬件库。

17.3.3 EGL接口解析

EGL接口是理解Android显示系统的关键，因为整个显示框架中都贯穿着各种eglXXX和glXXX的函数调用。如果无法掌握这些函数的功能和用法，那就好比“盲人摸象”一般，最终很可能会“事倍功半”。

以下接口的定义来源于：

frameworks/native/opengl/include/egl/Egl.h。

1．eglGetDisplay

函数原型：

```
EGLAPI EGLDisplay EGLAPIENTRY eglGetDisplay(EGLNativeDisplayType
```

因为OpenGL ES和OpenGL一样都是系统无关的（System Independent），所以在某一个特定的平台上使用它时，就涉及如何对其进行“本地化”处理的问题。EGL为OpenGL ES与本地的窗口系统提供了一个“中介”。

EGL面对的是各种各样的平台，而不同系统间的逻辑语义又存在或多或少的差异。可想而知，它需要一个机制来统一这些差异。接口eglGetDisplay得到的EGLDisplay就是一个与具体系统平台无关的对象（实际上是一个void*类型的变量）。对于任何使用EGL的应用来说，首先就需要调用eglGetDisplay来取得设备的Display。

一般情况下，我们为函数入参EGLNativeDisplayType指定的类型是EGL_DEFAULT_DISPLAY(0)，即默认的显示屏；并且要注意检查函数的返回值是否为有效值，例如下面的代码段：

```
EGLDisplay display;
display = eglGetDisplay(EGL_DEFAULT_DISPLAY);//取得默认显示屏
if( display == EGL_NO_DISPLAY || eglGetError() != EGL_SUCCESS )
{
   //错误处理
}…
```

后面我们还会看到EGLDisplay的更多使用场景。

2．eglGetError

函数原型：

```
EGLAPI EGLint EGLAPIENTRY eglGetError(void);
```

前面的例子中我们已经用过eglGetError了，它用于返回当前EGL中已经发生的错误。因为大部分EGL函数只会返回EGL_TRUE或者EGL_FALSE来表示成功和失败，所以开发人员要主动调用eglGetError来获取具体的失败原因（这个函数得到的是一个int值，代表了失败原因的编号）。

3．eglInitialize

函数原型：

```
EGLAPI EGLBoolean EGLAPIENTRY eglInitialize(EGLDisplay dpy, EGLin
```

成功执行了eglGetDisplay后，我们还需要对EGL进行初始化。这个函数将对EGL的内部数据进行初始值设定，并返回当前的版本号（即最后两个major和minor参数）。

可能的失败原因包括：

EGL_BAD_DISPLAY：指定的EGLDisplay无效。

EGL_NOT_INITIALIZED：无法正常完成初始化。

4．eglGetConfigs

函数原型：

```
EGLAPI EGLBoolean EGLAPIENTRY eglGetConfigs(EGLDisplay dpy,
EGLConfig *configs, EGLint config_size, EGLint *num_config);
```

初始化EGL完成后，下一步要获取一个最佳的Surface。方法有两种：其一是通过查询当前系统中所有Surface 的配置（Configuration），然后手动选择一个：其二就是填写我们的需求，然后由EGL推荐一个最佳匹配的Surface。

这个函数的使用分为两种情况。

- 如果将入参configs设为NULL，则能得到当前系统中所有Surface配置的数量（numConfigs）。
- 否则，我们需要指定maxReturnConfigs，然后EGL会把结果填充到configs中。

5．eglGetConfigAttrib

函数原型：

```
EGLAPI EGLBoolean EGLAPIENTRY eglGetConfigAttrib(EGLDisplay dpy,
EGLConfig config, EGLint attribute, EGLint *value);
```

EGLConfig包含了一个有效Surface的所有详细信息，如颜色数量、额外的缓冲区、Surface类型等重要属性。我们可以通过eglGetConfigAttrib来指定需要查看的具体属性项，表17-1列出了部分可选的属性。

表17-1 EGLConfig支持的属性

属 性	默 认 值	描 述
EGL_BUFFER_SIZE	0	颜色位数

EGL_RED_SIZE	0	红色位数
EGL_GREEN_SIZE	0	绿色位数
EGL_BLUE_SIZE	0	蓝色位数
EGL_LUMINANCE_SIZE	0	亮度位数

……

6．eglChooseConfig

函数原型：

```
EGLAPI EGLBoolean EGLAPIENTRY eglChooseConfig(EGLDisplay dpy, con
*attrib_list, EGLConfig *configs, EGLint config_size, EGLint *num
```

前面说过，除了手动逐个查阅EGLConfig，然后选择一个最佳配置外，我们还可以让EGL自动选择并直接返回匹配结果。使用eglChooseConfig需要我们先提供一系列需求清单——这就好比去商城配一部组装电脑一样，先要详细填写期望的硬件配置，然后商家才能依据这一需求来提供性价比最高的组装方案。

7．eglCreateWindowSurface

函数原型：

```
EGLAPI EGLSurface EGLAPIENTRY eglCreateWindowSurface(EGLDisplay d
EGLConfig config, EGLNativeWindowType win, const EGLint *attrib_l
```

一旦我们选择好最佳的EGLConfig，接下来就可以创建一个window了。注意函数eglCreateWindowSurface最后的attrib_list和前面一个表中列出的属性不太一样，建议读者参阅官方文档了解详情。

函数eglCreateWindowSurface可能发生的错误如表17-2所示。

表17-2 eglCreateWindowSurface可能发生的错误

错 误 码	描 述
EGL_BAD_MATCH	本地窗口（native window）和EGLConfig不相符，或者我们提供的EGLConfig不支持window渲染
EGL_BAD_CONFIG	系统不支持这个EGLConfig
EGL_BAD_NATIVE_WINDOW	提供的本地窗口句柄（native window handle）是无效的
EGL_BAD_ALLOC	无法分配足够的资源

8．eglCreatePbufferSurface

函数原型：

```
EGLAPI EGLSurface EGLAPIENTRY eglCreatePbufferSurface(EGLDisplay
EGLConfig config, const EGLint *attrib_list);
```

这个函数与上面的eglCreateWindowSurface一样都用于创建一个Surface——但Surface的用途不同。前者生成的Surface可用于在终端屏幕上显示，而eglCreatePbufferSurface生成的结果则是“离屏”（off-screen）的渲染区。所有适用于window surface的渲染方法同样能被pbuffer surface使用，只不过执行的结果不需要通过swap buffer来最终输出到屏幕上。当然，读者可以选择将数据保存到指定的地方。

9．eglCreateContext

函数原型：

```
EGLAPI EGLContext EGLAPIENTRY eglCreateContext(EGLDisplay dpy,
EGLConfig config, EGLContext share_context, const EGLint *attrib_
```

我们知道，OpenGL是一个状态机，需要对诸多状态进行管理。EGL Context正是基于这个需求提出来的，它为OpenGL的运行提供了统一的环境，并让我们可以依托于这个环境来更好地控制OpenGL。

这个函数可能的错误结果包括。

EGL_NO_CONTEXT：无法创建context。

EGL_BAD_CONFIG：提供了无效的EGLConfig。

10．eglMakeCurrent

函数原型：

```
EGLAPI EGLBoolean EGLAPIENTRY eglMakeCurrent(EGLDisplay dpy, EGLS
draw, EGLSurface read, EGLContext ctx);
```

一个进程中可能会同时创建多个Context，所以我们必须选择其中的一个作为当前的处理对象。细心的读者应该发现了这个函数的入参中有两个EGLSurface，那么哪个才是要被设置的当前Surface呢？答案就是“两个都是”。所以，通常情况下我们需要把两者都设为同一个Surface。至于系统为什么这样设计，这里不过多追究，感兴趣的读者可以查阅相关资料。

至此，我们按照一个典型程序中使用EGL的顺序讲解了它所提供的几个重要接口函数。只有成功地调用并执行这些接口，才能保证OpenGL ES的正常运行。

17.3.4 EGL实例

这个例子选取自Android显示系统——SurfaceFlinger通过EGL来搭建OpenGL ES的运行环境。其源码实现所在目录为：

```
frameworks/native/services/surfaceflinger/SurfaceFlinger.cpp
```

具体是在readyToRun中，如下所示：

```
status_t SurfaceFlinger::readyToRun()
{…
    Mutex::Autolock _l(mStateLock);
    mEGLDisplay = **eglGetDisplay**(EGL_DEFAULT_DISPLAY); /*Step
******eglInitialize**(mEGLDisplay, NULL, NULL); /*Step 2.初始化*/
    …
    EGLint format = mHwc->getVisualID();
    mEGLConfig  =** selectEGLConfig**(mEGLDisplay, format); /*Ste
                                                     最佳的conf
    mEGLContext = **createGLContext**(mEGLDisplay, mEGLConfig); /
******eglGetConfigAttrib**(mEGLDisplay, mEGLConfig,
          EGL_NATIVE_VISUAL_ID, &mEGLNativeVisualId); /*Step 5. 获
    …
    sp<const **DisplayDevice**> hw(getDefaultDisplayDevice());/*S
                           DisplayDevice，其构造函数中会调用eglC
    DisplayDevice::**makeCurrent**(mEGLDisplay, hw, mEGLContext);
                                                              Co
    …
    return NO_ERROR;
}
```

可以看到，上述代码段的处理过程和前面小节的讲解完全一致。读者还可以在Android工程中的其他地方找到类似的例子，如BootAnimation，GLSurfaceView等。

17.4 简化OpenGL ES开发——GLSurfaceView

一直以来我们看到的范例都是以C/C++编写的，那么Java层能否使用EGL和OpenGL ES呢？答案是肯定的。

这一小节，我们将讲解上层应用程序如何使用OpenGL ES。和其他常用功能一样，Android系统已经在SDK中为开发人员封装了一整套OpenGL ES的使用和管理机制。具体而言，Java层代码可以通过以下两种方式来搭建OpenGL ES环境。

- 直接使用SDK提供的EGL，GLES类（Java）

与EGL相关的Java类包括EGL10、EGL11、EGL14和EGL等；与GLES相关的Java类包括GLES10、GLES11、GLES20、GLES30等。这些类将间接通过JNI调用C/C++层的EGL和GLES实现。

- GLSurfaceView

虽然用户可以直接通过EGL和GLES提供的Java层接口来使用OpenGL ES，但这种方式对开发人员有一定要求，程序编写上也比较复杂。所以Android系统特别封装了GLSurfaceView，从而大大精简了应用开发者的工作。

GLSurfaceView继承自SurfaceView，也就意味着它具备View类的所有功能和属性——特别是接收事件的能力，这弥补了OpenGL ES本身不能响应任何事件的缺陷（准确地说并不是缺陷，因为它的设计初衷就是这样的）；同时，GLSurface View也拥有了OpenGL ES所提供的强大的3D图形处理功能，这为我们编写高质量的UI界面或者游戏特效提供了坚实的基础，如图17-10所示。

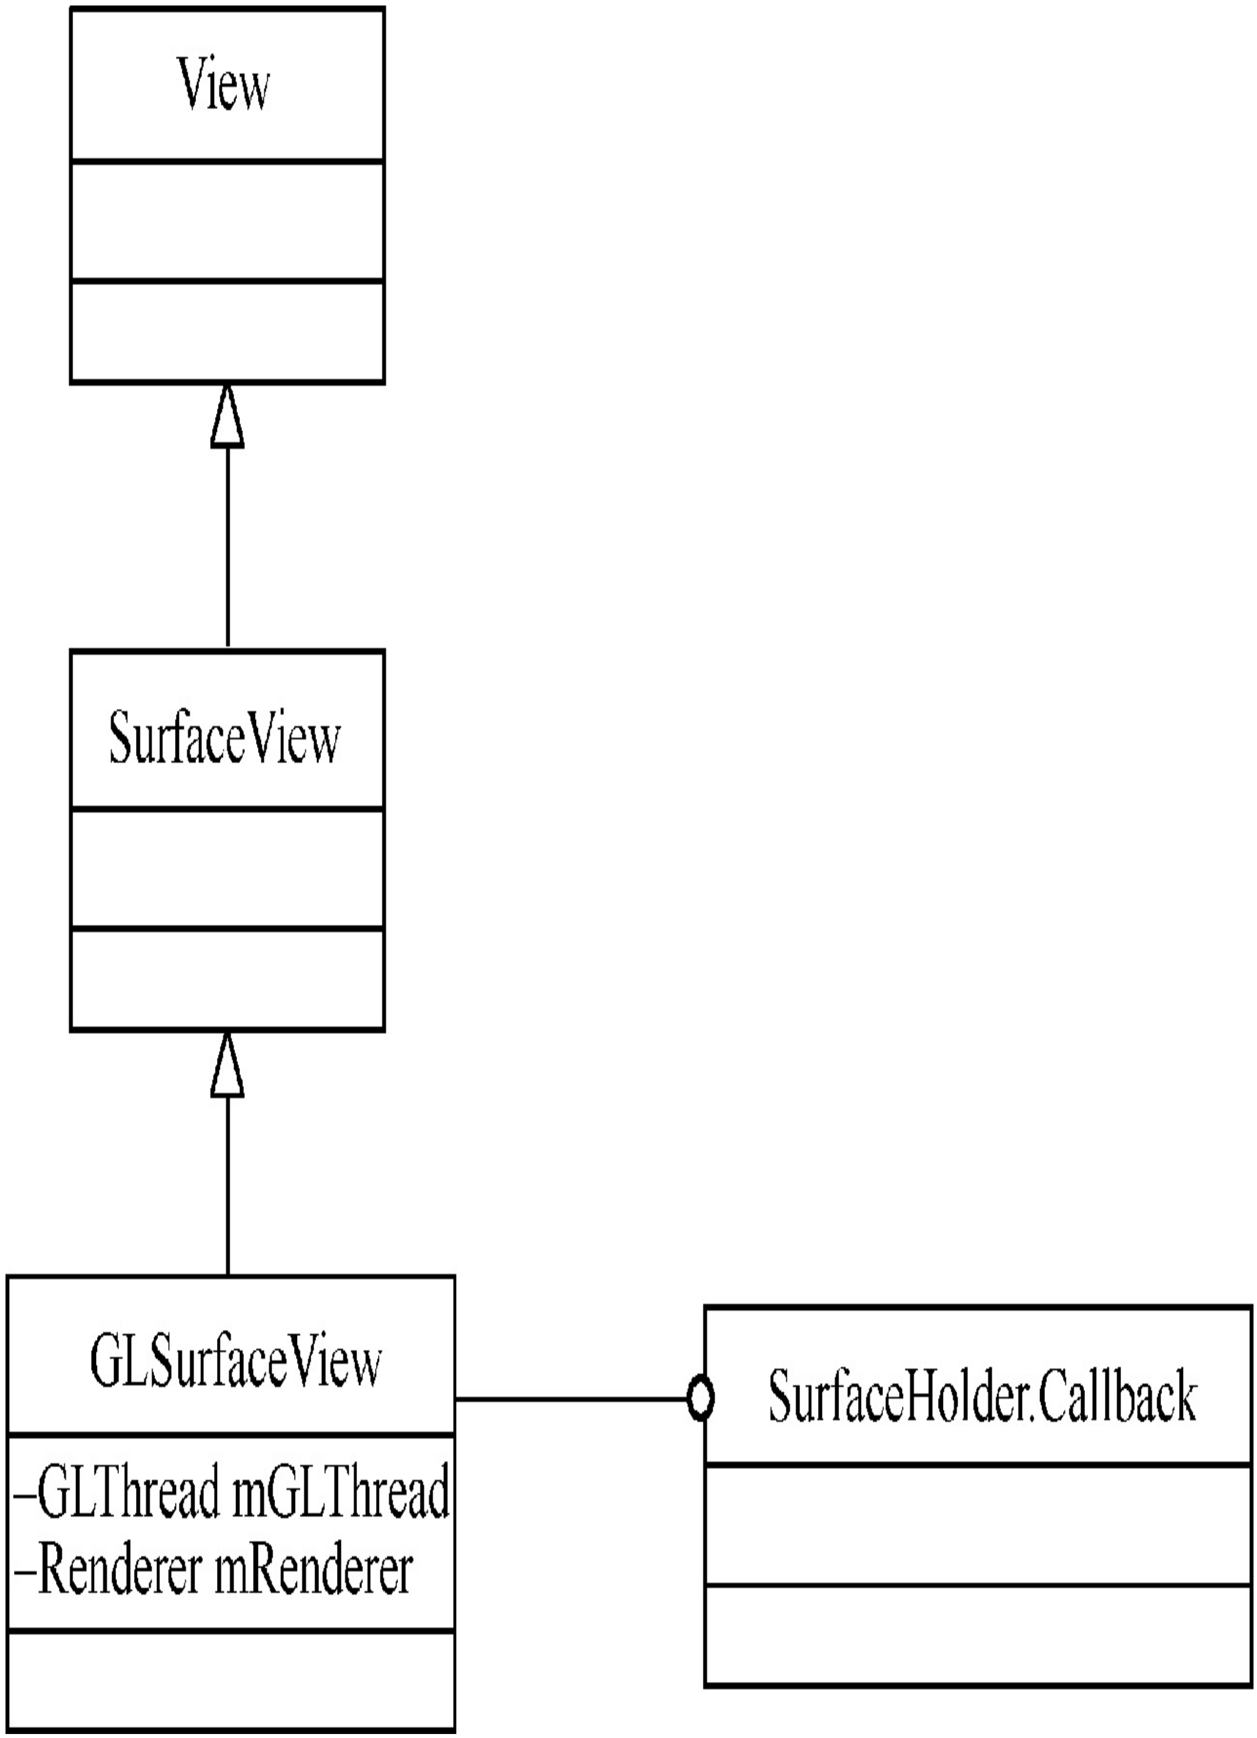
View
SurfaceView
GLSurfaceView
–GLThread mGLThread
–Renderer mRenderer
SurfaceHolder.Callback

▲图17-10 GLSurfaceView继承关系图

GLSurfaceView的主要特性：

- 管理EGLDisplay，它表示一个显示屏；
- 管理Surface（本质上就是一块内存区域）；
- GLSurfaceView会创建新的线程，以使整个渲染过程不至于阻塞UI主线程；
- 用户可以自定义渲染方式，如通过setRenderer()设置一个Renderer。

可以肯定地说，当前很多Android游戏都是直接或者间接通过GLSurfaceView完成的。因而，熟练掌握它的使用方法是游戏开发人员的必修课。基本步骤如下：

Step1．创建GLSurfaceView

这和普通的应用程序并没有什么区别——因为GLSurfaceView也是一个View，我们可以通过布局文件的方式将它加入整棵View树中。

Step2．初始化OpenGL ES环境

GLSurfaceView默认情况下已经为开发人员搭建好OpenGL ES的运行环境，因而如果没有特殊需求，我们并不需要额外做什么工作。当然，所有的默认设置都是可以被更改的。比如通过以下这些函数：

```
setEGLConfigChooser(boolean)
setGLWrapper(GLWrapper)
getHolder().setFormat(PixelFormat.TRANSLUCENT)
setDebugFlags(int)
```

具体细节可以参阅帮助文档。

Step3．设置Renderer

渲染是OpenGL的核心工作，也是开发人员花费时间最多的地方。SetRenderer()可以将用户自定义的一个Renderer加入实际的渲染流程中：

Step4. 设置Rendering Mode

GLSurfaceView默认情况下采用的是连续的渲染方式，如果需要开发人员可以通过setRenderMode来进行更改。

Step5. 状态处理

使用GLSurfaceView要特别注意程序的生命周期。我们知道Activity会有暂停和恢复等状态，为了达到最优效果，GLSurfaceView也必须要知晓程序的当前状态。比如当Activity暂停时需要调用GLSurfaceView的onPause()，恢复时再调用onResume()等——这样才能使OpenGL ES内部的运行线程做出正确的判断，从而保证应用程序的稳定性。

总结以上几个步骤可以发现，如果开发过程基于GLSurfaceView，那么我们的主要工作就只有Renderer的实现了。而其他诸如EGL的创建过程、Surface的分配以及OpenGL ES的一些调用细节等都被隐藏了起来。

GLSurfaceView是如何做到的呢？接下来我们就要深入源码层去探个究竟了。

先来看看GLSurfaceView的创建过程。

```
  /*frameworks/base/opengl/java/android/opengl/GLSurfaceView.
public GLSurfaceView(Context context, AttributeSet attrs) {
    super(context, attrs);
    init();
}
```

GLSurfaceView的构造函数很简捷，除了调用其父类（即SurfaceView）的构造函数外，就直接进入init()：

```
  private void init() {
    SurfaceHolder holder = getHolder(); //SurfaceView中的方法
    holder.addCallback(this);
}
```

这个函数也很简单，它先通过“父类”SurfaceView的方法获取当前的SurfaceHolder，然后添加自身为回调函数（因为它实现了

SurfaceHolder.Callback），这样当Surface有变化（比如创建、销毁）时就能收到通知了。

这个Callback接口中有3个重要的方法。如下所示：

```
void surfaceCreated(SurfaceHolder holder);
```

当成功申请到一个Surface时调用，一般情况下只会发生一次：

```
void surfaceChanged(SurfaceHolder holder, int format, int width,i
```

当Surface改变时调用，如format，size的更动：

```
void surfaceDestroyed(SurfaceHolder holder);
```

当Surface销毁时调用。

特别提醒一下，读者不要将这里的Callback和GLSurfaceView.Renderer里的回调函数相混淆。后面这个接口有如下几个回调方法：

```
void onSurfaceCreated(GL10 gl, EGLConfig config);
void onSurfaceChanged(GL10 gl, int width, int height);
void onDrawFrame(GL10 gl);
```

它是GLSurfaceView与APK应用程序间的回调，而Surface被销毁的事件应用程序不需要关心，因而就没有这个接口存在。

那么，SurfaceHolder又是如何创建的呢？

```
/*frameworks/base/core/java/android/view/SurfaceView.java*/
private SurfaceHolder mSurfaceHolder = new SurfaceHolder() {…
        public void addCallback(Callback callback) {
            synchronized (mCallbacks) {
                if (mCallbacks.contains(callback) == false) {
                    mCallbacks.add(callback);
                }
            }
        }
      …
}
```

在SurfaceView中，mSurfaceHolder是它的一个全局变量，而且一开始就已经创建了实例。其中的addCallback()方法用于将需要接收回调通知的类（比如上面的GLSurfaceView）加入其mCallbacks队列管理中。

接下来看看Surface是如何创建的。我们知道，SurfaceView继承自View，而应用程序的View树一定会通过ViewRoot申请到一个Surface（这个过程可以参阅ViewRoot章节的讲解）。那么，SurfaceView中的这个Surface与ViewRoot的Surface是否属于同一个呢？

答案是否定的。SurfaceView中的Surface是另外分配得到的——这也是它“SurfaceView”名称的由来。我们来看看SurfaceView对象是如何申请到自己的Surface的，如图17-11所示。

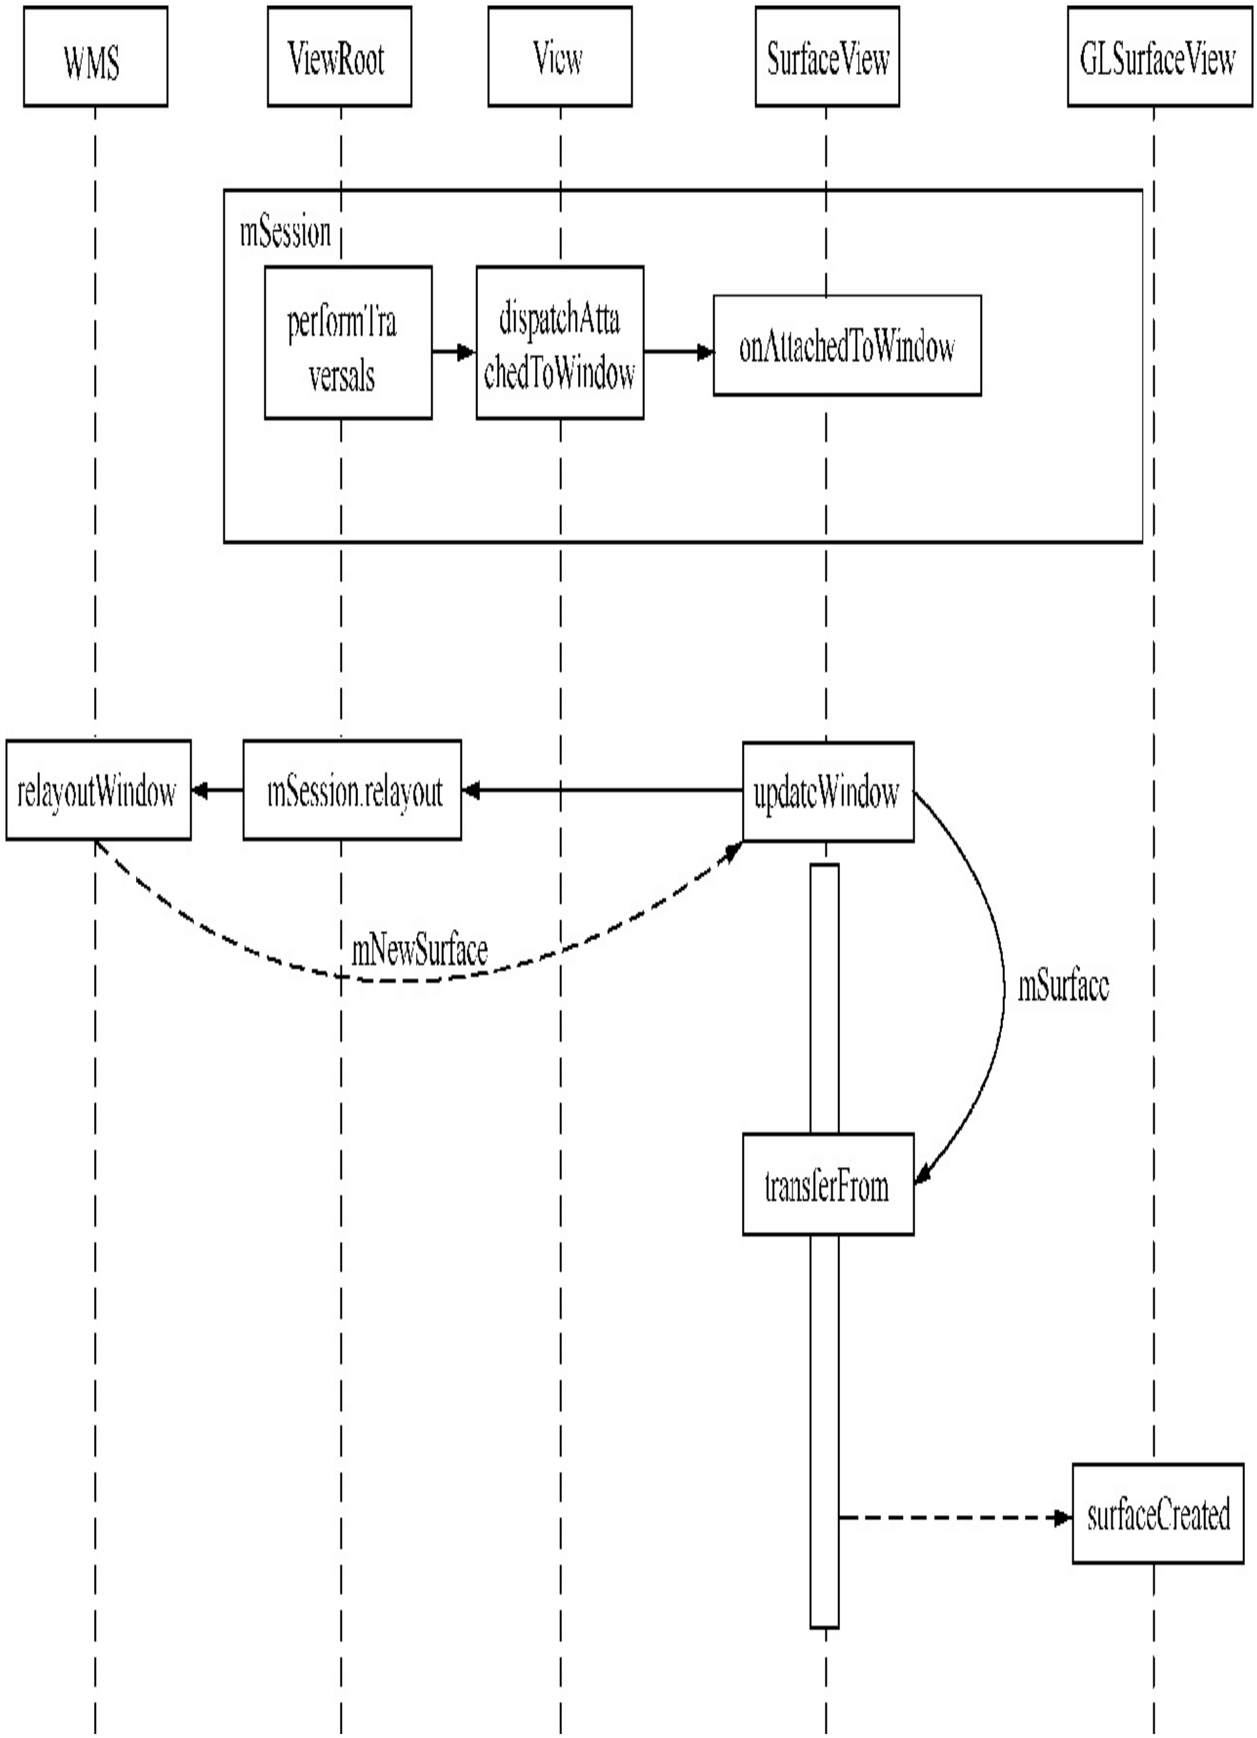

WMS
ViewRoot
View
SurfaceView
GLSurfaceView
mSession
performTra
versals
dispatchAtta
chedToWindow
onAttachedToWindow
relayoutWindow
mSession.relayout
updateWindow
mNewSurface
mSurface
transferFrom
surfaceCreated

▲图17-11 SurfaceView中Surface的申请过程

图17-11描述了SurfaceView中申请Surface的流程。包括如下几个步骤：

- 当ViewRoot成功AttachToWindow后，它需要将这一事件告知View树中的所有成员（其中的performTraversals我们在ViewRoot章节中有重点分析）。要注意的是，一般情况下SurfaceView都是布局在某个ViewGroup中的。比如我们写一个Media Player，最外围的layout通常是FrameLayout，然后依次叠加视频播放层（SurfaceView）、控制层（按键、菜单）等。因而ViewGroup中必须重载dispatchAttachedToWindow这个方法，才有可能将这个消息传播到View树的每个角落。其他事件在View树中的递归传递也类似。
- SurfaceView在收到AttachedToWindow成功的消息后，会通过getWindowSession()向ViewRoot获取一个IWindowSession。这是ViewRoot与WMS间的通信中介，SurfaceView没有必要自己再新建一个，直接用现成的即可。
- SurfaceView在updateWindow()时，将利用IwindowSession.relayout()来重新申请一个Surface，其中最后一个参数就是WMS生成的新Surface。
- SurfaceView取得新的Surface后，会Transfer到mSurface变量中。此时还需要把这一事件通知到所有注册了callback函数的对象，如GLSurfaceView。这样SurfaceView“独享”的一个全新Surface就申请成功了。

当获知Surface已经申请成功后，GLSurfaceView还需要做些什么工作呢？

```
  /*frameworks/base/opengl/java/android/opengl/GLSurfaceView.
public void surfaceCreated(SurfaceHolder holder) {
    mGLThread.surfaceCreated();
}
```

前面说过，GLSurfaceView将会启动一个新线程来完成渲染，以防止程序阻塞UI主线程——这个新的工作线程就是mGLThread。它将在应

用程序调用setRenderer()时启动，然后不断等待和处理事件，同时还负责开展Render工作：

```
    public void surfaceCreated() {
         synchronized(sGLThreadManager) {…
             mHasSurface = true;
             sGLThreadManager.notifyAll();
         }
     }
```

这里又出现了一个新的变量sGLThreadManager，从名称上看它和Thread相关，而且是GLThread的“管理者”。具体来说，它管理的是不同线程间的互斥访问。如果读者对wait()、notifyAll()、notify()、synchronized()这些函数的用法还不太清楚，建议回头看看本书的原理篇章节，这里不再赘述。

有notify()或者notifyAll()就意味着肯定有其他地方在wait()。唯一可以找到的相关代码是GLThread中的guardedRun()方法（注意：上面的surfaceCreated函数并不是在GLThread线程中执行的），我们只截取最核心部分的代码来分析。如下所示：

```
private void guardedRun() throws InterruptedException {
    …
******while** (true) {//死循环，除非主动跳出
     synchronized (sGLThreadManager) {
**while** (true) { //注意嵌套了两个while循环，下面我们统一称它们内、外循环
            if (mShouldExit) {//是否需要结束循环
               return;
            }
            if (! mEventQueue.isEmpty()) { /*Step1.从EventQueue中获
               event = mEventQueue.remove(0); //取得这一消息
               break; /*注意：只是跳出内循环*/
            }…
            /*Step2.下面的工作基于各种全局变量展开，我们依次分析(同样只保留
           if (pausing && mHaveEglSurface) {…//释放Surface。比如Act
                stopEglSurfaceLocked();
            }
           if ((! mHasSurface) && (! mWaitingForSurface)) {//判断S
           /*如果当前没有Surface，而且也不在等待Surface的创建，说明已经失
                if (mHaveEglSurface) {
                  stopEglSurfaceLocked ();
               }
              mWaitingForSurface = true;
                 mSurfaceIsBad = false;
```

```
                sGLThreadManager.notifyAll();
            }
            if (mHasSurface && mWaitingForSurface) {/*如果已经成功获
                                                    设置相应的全局变量
               …
               mWaitingForSurface = false;
               sGLThreadManager.notifyAll();//并通知任何正在等待的线程
            }…
            if (**readyToDraw**()) {
                …/*Step3. GLSurfaceView最核心的工作就是根据应用程序设置
                   渲染处理,后面专门讲解*/
            }…
            sGLThreadManager.**wait**(); //如果上述readyToDraw中没有
        } //内循环(while循环)结束
    } // synchronized(sGLThreadManager)到这边结束
    /*Step4.程序如果执行到这里，有两种可能：QueueEvent中有事件，或者要执行
    if (event != null) {//有事件要处理的情况下，调用它的run函数
         event.run();
         event = null;
         continue;//事件执行完毕后直接进入下一轮循环
    }
    if (createEglSurface) {/*内围while循环如果设置了这个标志，说明EglSu
      …//代码略
    }…
    if (sizeChanged) {…
          GLSurfaceView view = mGLSurfaceViewWeakRef.get();
          if (view != null) {
               view.mRenderer.onSurfaceChanged(gl, w, h); /*通知应
          }
          sizeChanged = false;
    }
    {
          GLSurfaceView view = mGLSurfaceViewWeakRef.get();
          if (view != null) {
               view.mRenderer.**onDrawFrame**(gl); //调用应用程序的R
          }
    }
    int swapError = mEglHelper.**swap**(); //通过swap把渲染结果显示到
    … //swap错误的处理，代码略
}//外围的while循环
```

函数guardedRun很长，但核心工作总结起来只有以下几点。

- 整个函数的逻辑框架分为内、外两层while循环。
- 如果事件队列（mEventQueue）“有东西”，就直接跳出内循环，然后进入外循环的处理部分（Step4）。

- 否则要根据当前的状态看是否适合渲染、是否有事件要通知应用程序等。
- 如果确定需要做渲染工作，同样跳出内循环。
- 处理事件或者执行渲染工作（Step4以后）。
- 如此循环往复。

详细分析如下：

Step1@guardedRun。内循环中，首先判断mEventQueue.isEmpty是否为空——如果发现Queue中有event需要处理，则直接跳出内循环（即进入Step4）；否则仍然运行在内循环中。

Step2@guardedRun。需要判断的情况包括：

（1）是否需要释放EGL Surface。

比如当前的Activity已经处于pause状态。

（2）是否丢失了Surface。

在某些异常情况下是有可能丢失掉Surface的。因而我们需要特别防止这种情况的发生。变量mHasSurface表示当前有没有可用Surface；mWaitingForSurface表示是否在申请Surface的过程中。

（3）是否需要放弃EGL Context。

当有人调用requestReleaseEglContextLocked申请释放Context时，变量mShouldReleaseEgl Context将被置为true，此时需要调用stopEglSurfaceLocked和stopEglContextLocked来中止Context。

……

Step3@guardedRun。经过上述判断后，程序进入图形渲染前的准备工作，即readyToDraw之间的代码段。如下所示：

```
if (readyToDraw()) {
     if (! mHaveEglContext) {//没有EGL Context的情况下
        ..//判断是否要建立有效的Context
     }
```

```
        …
        if (mHaveEglSurface) { // 保证我们有EglSurface，注意和mSur
            …
            mRequestRender = false;
            sGLThreadManager.notifyAll();
            break;
        }
    }
```

上述这段代码执行的前提是当前可以渲染图形（readyToDraw），即需要满足以下几个条件。

（1）程序当前不处于暂停状态。

（2）已经成功获得Surface。

（3）有合适的尺寸。如果长宽都为0，就没有显示的意义了。

（4）处于持续自动渲染模式，或用户主动发起了渲染请求。

接着判断两个关键因素，即EGL Context和EGL Surface是否存在并且有效。如果没有Context，就需要获取一个；如果当前有EglSurface，但尺寸发生了变化，那么就需要销毁它并重新申请Surface。

假如一切正常，上面代码段的末尾会跳出内围的while循环——否则程序会进入wait()，直到有人唤醒它后才继续执行循环。

Step4@guardedRun。一旦程序执行到这里（即跳出了内循环），有两种可能：

- EventQueue中有需要处理的事件

此时event变量不为空，所以我们直接调用event.run来执行具体工作；并且在事件处理结束后直接进入下一轮循环（continue）。

- 需要执行渲染工作

如果是后面一种情况，处理流程如下。

（1）是否需要重新申请EglSurface。

比如尺寸发生了变化，此时createEglSurface为true。

（2）是否需要申请GL Object。

此时createGlInterface为true。

（3）是否需要生成EGL Context。

此时createEglContext为true。

（4）尺寸是否发生变化。

此时sizeChanged为true，我们需要将此事件通知给感兴趣的人。即调用：

```
view.mRenderer.onSurfaceChanged(gl, w, h);
```

（5）一切准备就绪后，我们调用开发者提供的Render对象执行真正的渲染工作：

```
view.mRenderer.onDrawFrame(gl);
```

（6）最后，我们需要通过swap来把渲染结果显示到屏幕上（中间的详细流程可以参考显示系统章节的描述）。如果swap失败，还应该做好处理工作。

在分析guardedRun()的过程中，读者应该已经注意到对EGL的操作全部是通过EglHelper来进行的——这是系统对EGL的一层便捷封装。下面具体来看看EglHelper所做的工作：

```
private class EglHelper {…
   public void start() {…
       mEgl = (EGL10) EGLContext.getEGL(); //取得一个EGL实例
       mEglDisplay = mEgl.eglGetDisplay(EGL10.EGL_DEFAULT_DI

       …
       /*接着用上述的EglDisplay来初始化EGL实例*/
       int[] version = new int[2];
       if(!mEgl.eglInitialize(mEglDisplay, version)) {//初始化
```

```
            throw new RuntimeException("eglInitialize failed"
        }
        GLSurfaceView view = mGLSurfaceViewWeakRef.get();
        if (view == null) {
            mEglConfig = null;
            mEglContext = null;
        } else {
            mEglConfig = view.mEGLConfigChooser.chooseConfig(
            /*选取一个EGL配置*/
            mEglContext = view.mEGLContextFactory.createConte
            Config);/*创建EGLContext，它是控制OpenGL ES状态机运转
        }
        …
    }
```

完成start()后，就可以利用EGL结合用户设置的Renderer进行OpenGL ES的渲染了。最后通过EglHelper.swap()来将Surface中的内容显示到屏幕上。其中swap()方法本身并不复杂，核心语句如下所示。

```
mEgl.eglSwapBuffers(mEglDisplay, mEglSurface);
```

所以抛开上述分析中的所有封装和一系列细节处理，GLSurfaceView中使用EGL的步骤大致如下。

- 获取一个EGL实例

```
EGLContext.getEGL();
```

- 获取一个EGL Display

```
eglGetDisplay(Object native_display);
```

- 利用Display来初始化EGL并返回EGL的版本号

```
eglInitialize(EGLDisplay display, int[] major_minor);
```

- 选取EGL的一个配置 (EGL Config)

```
eglChooseConfig(EGLDisplay display, int[] attrib_list, EGLConfig[
```

- 创建EGL Context

```
eglCreateContext(EGLDisplay display, EGLConfig config, EGLContext
```

- 创建EGL Surface

```
eglCreateWindowSurface(EGLDisplay display, EGLConfig config, Obje
int[] attrib_list);
```

- 通过Swap来将渲染内容显示到屏幕上

```
eglSwapBuffers(EGLDisplay display, EGLSurface surface);
```

GLSurfaceView中所涉及的EGL接口都是Java层的，而且很好地封装在了GLSurfaceView的框架中——这就意味着GLSurfaceView的使用者几乎不用添加任何代码便拥有了OpenGL ES的运行环境，可谓一举多得。

17.5 OpenGL分析利器——GLTracer

由于OpenGL的动态性，对它所生成的UI界面的追踪调试成了一个难点。譬如大部分游戏类应用程序就是基于Cocos2D/3D、Unity3d、Unreal等GameEngine开发的，而后者则又会利用OpenGL来完成图形界面的绘制。游戏画面的变换相当频繁，如何有效地追踪图形相关问题显得尤其重要。那么Android有没有提供OpenGL方面的工具来辅助我们完成上述问题的分析呢？

答案就是GLTracer。

GLTracer可以让开发者方便地捕抓到OpenGL ES的接口调用信息，以及由此产生的每一帧图像。不过它对Android系统版本有一定要求，Android 4.1（API等级16）以上才能正常使用这一开发利器。开发者可以从Android Device Monitor或者各IDE中启动这个工具。

开始一个OpenGL Trace的流程如下所示。

- 通过USB线连接Android真机设备，同时要保证设备开启了调试模式。
- 打开Tracer for OpenGL ES窗口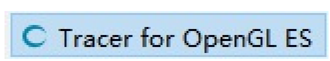

。
- 单击捕抓Trace的按钮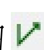。
- 在打开的对话框中，首先选择需要调试的OpenGL程序所在的设备，如图17-12所示。

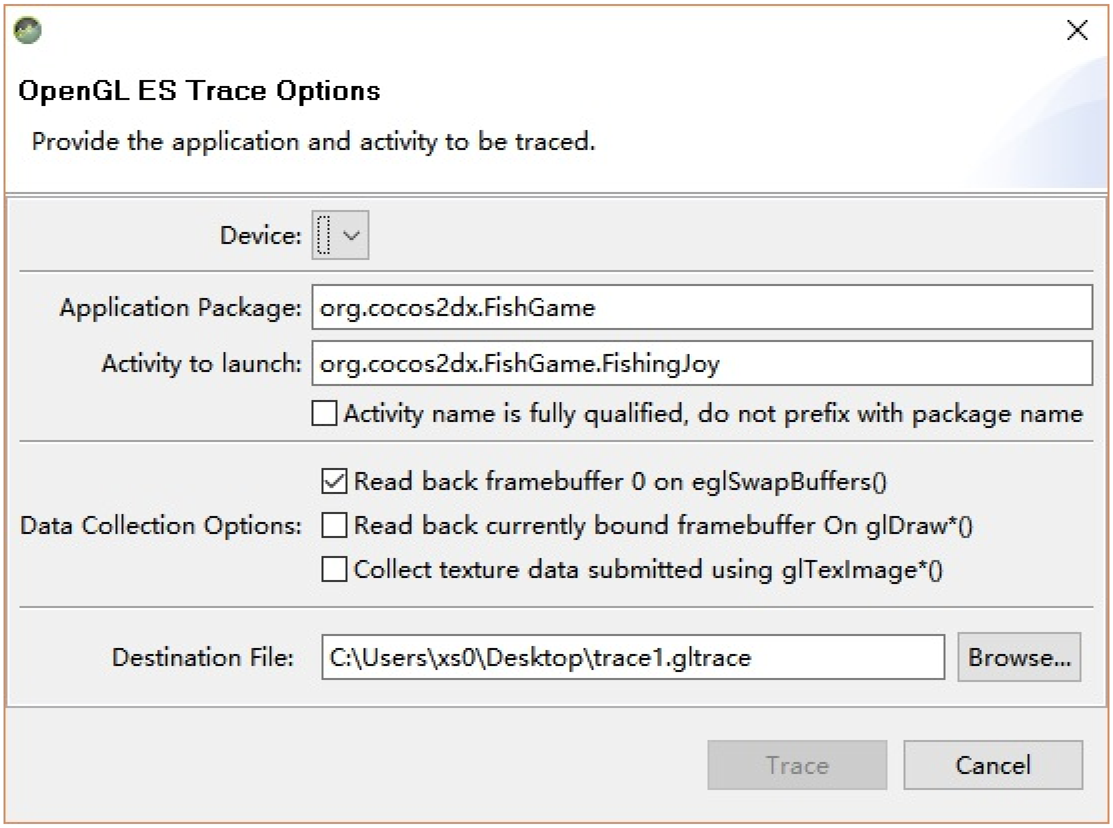

▲图17-12 选择要调试的设备

- 在Application Package中，输入希望调试的OpenGL程序的包名。
- 在Activity to launch中，输入希望调试的Activity。当然，如果要被调试的对象是默认的Activity，那么可以不必填写。
- 选择Trace的保存路径。
- 单击Trace按钮开始捕获数据。
- 如果希望调试Trace文件，可以单击Open a saved OpenGL Trace File按钮。

这个工具还有另一个限制，即被测试的应用程序必须是debuggable的。这就要求开发人员在AndroidManifest.xml中主动添加这一属性，如下面范例所示：

```
<application
    android:icon="@drawable/ic_launcher"
    android:label="@string/app_name"
    android:theme="@style/AppTheme"
    android:**debuggable**="true">
```

如果被测程序不符合上述要求的话，系统将抛出一个Security的异常。对应的源码实现在ActivityManagerService.java中：

```
    void setOpenGlTraceApp(ApplicationInfo app, String processNam
        synchronized (this) {
        boolean isDebuggable = "1".equals(SystemProperties.get(SY
            if (!isDebuggable) {
                if ((app.flags&ApplicationInfo.FLAG_DEBUGGABLE) =
                 throw new SecurityException("Process not debugga
                }
            }
            mOpenGlTraceApp = processName;
        }
    }
```

SYSTEM_DEBUGGABLE（这是一个全局静态字符串变量，值为“ro.debuggable”）这一属性在不同设备中的具体值会存在一定差异（主要取决于编译版本的variant设置，如user、userdebug或者是eng）。这就意味着如果我们希望在已量产的Android设备中调试第三方的应用程序的话，就需要对设备本身做一些特殊处理。

下面我们来分析一下GLTracer的内部实现原理。

GLTracer的源码也在Android工程中，具体路径是sdk\eclipse\plugins\com.android.ide.eclipse. gldebugger。为了让大家可以快速地理解整个流程，我们下面只提取实现中最核心的部分，如下所示：

```
/*sdk\eclipse\plugins\com.android.ide.eclipse.gldebugger\src\com\
    private void connectToDevice() {
        Shell shell = Display.getDefault().getActiveShell();//She
        GLTraceOptionsDialog dlg = new **GLTraceOptionsDialog**(s
         /* GLTraceOptionsDialog是前述我们看到的选项配置对话框*/
        if (dlg.open() != Window.OK) {
            return;
        }
        TraceOptions traceOptions = dlg.getTraceOptions();//获取用
        IDevice device = getDevice(traceOptions.device);//目标设备
        …
        try {
**setupForwarding**(device, LOCAL_FORWARDED_PORT);
        } catch (Exception e) {
            MessageDialog.openError(shell, "Setup GL Trace",
                    "Error while setting up port forwarding: " +
```

```
            return;
        }
        try {
            if (!SYSTEM_APP.equals(traceOptions.appToTrace)) {
**startActivity**(device, traceOptions.appToTrace,
                        traceOptions.activityToTrace,
                        traceOptions.isActivityNameFullyQualified
            }
        } catch (Exception e) {
            MessageDialog.openError(shell, "Setup GL Trace",
                    "Error while launching application: " + e.get
            return;
        }
        // if everything went well, the app should now be waiting
        // to connect
**startTracing**(shell, traceOptions, LOCAL_FORWARDED_PORT);
        // once tracing is complete, remove port forwarding
        disablePortForwarding(device, LOCAL_FORWARDED_PORT);
        // and finally open the editor to view the file
        openInEditor(shell, traceOptions.traceDestination);
    }
```

其中最关键的几个步骤是:

Step1. Port Forwarding

通过端口转发，让运行于PC上的程序可以与运行于终端手机/模拟器上的程序直接通过TCP/IP进行通信。具体实现函数是createForward@IDevice，有兴趣的读者可以自行分析源码了解详情。在我们这个场景中，需要将Unix Domain Socket Name为“gltrace”的服务转发到6039来完成Client/Server式的通信机制。

Step2. 显示GLTraceOptionsDialog，用于收集用户针对GLTracer的各个配置值

包括目标设备、需要被追踪的包名和Activity信息等。

Step3. 调用startActivity来启动需要被追踪的目标程序

这个startActivity显然不是我们在Android应用程序开发中经常使用的startActivity。它的主要职责是利用/system/bin/am来启动目标程序，具体命令如下:

"am start --opengl-trace %s -a android.intent.action.MAIN -c android.intent.category.LAUNCHER"

其中“%s”是由目标程序的包名和Activity名称组成的字符串；“-a”选项表示需要为Intent添加一项Action；“-c”表示添加Category。至于am对此命令的处理流程，我们稍后会做介绍。

Step4. 调用startTracing，开始接收Server端发送过来的Trace数据

Step5. 以图形化的方式显示上述采集的数据

接下来我们从/system/bin/am的角度来分析，它是如何帮助GLTracer完成对程序中的OpenGL命令流追踪的，相关帮助信息如图17-13所示。

```
am start: start an Activity.  Options are:
    -D: enable debugging
    -W: wait for launch to complete
    --start-profiler <FILE>: start profiler and send results to <FILE>
    -P <FILE>: like above, but profiling stops when app goes idle
    -R: repeat the activity launch <COUNT> times.  Prior to each repeat,
        the top activity will be finished.
    -S: force stop the target app before starting the activity
    --opengl-trace: enable tracing of OpenGL functions
    --user <USER_ID> | current: Specify which user to run as; if not
        specified then run as the current user.
```

▲图17-13 帮助信息

系统bin目录下的am是一个shell脚本，它在准备好各种参数后，会直接调用前面章节分析过的app_process。我们知道，app_process除了承担在系统启动过程中运行Zygote的重任外，还支持运行一个虚拟机来承载外部用户传递进来的Java类。在我们这个场景中，被启动的主类是am，而后者又继承于BaseCommand。am重载了BaseCommand的onRun函数，用于解析外部传入的各种参数，以决定下一步的计划。

am在发现参数中的子命令是“start”后，调用runStart进行处理。如果是需要跟踪OpenGL命令的情况，那么主要的区别在于StartActivity时传入的Flag参数。具体而言，我们需要指定ActivityManager.START_FLAG_OPENGL_TRACES来保证

ActivityManagerService在启动目标Activity时可以正确按照开发者的意图进行处理。

服务端对于这个Flag的处理在resolveActivity@ActivityManagerSuperVisor.java中，核心代码如下所示：

```
/**/
    ActivityInfo resolveActivity(Intent intent, String resolvedTy
            ProfilerInfo profilerInfo, int userId) {…
            if ((startFlags&ActivityManager.START_FLAG_OPENGL_TRA
                if (!aInfo.processName.equals("system")) {
                    mService.setOpenGlTraceApp(aInfo.applicationI
                                                aInfo.processName)
                }
            }…
```

其中mService对应的是大家熟悉的ActivityManagerService，那么它在对待这种类型的程序时会做什么特殊处理呢？函数setOpenGlTraceApp在前面分析权限时大家已经遇到过了。这里假设我们可以成功通过权限的检测过程，这种情况下AMS就会把需要跟踪的程序添加到全局变量mOpenGlTraceApp中。

接着AMS会通过一系列的startActivity函数来启动目标进程和Activity，具体过程可以参考本书其他章节。目标进程准备就绪后，将回调attachApplication@ActivityManagerService。完成attach后AMS同样会通知目标进程，对应的函数是bindApplication@ActivityThread。不过程序并不会立即处理这个事件，而是通过H.BIND_APPLICATION来将其加入队列中。

ActivityThread对这个消息的处理分支如下：

```
            case BIND_APPLICATION:
               Trace.traceBegin(Trace.TRACE_TAG_ACTIVITY_MANAGER,
                   AppBindData data = (AppBindData)msg.obj;
                   handleBindApplication(data);
                   Trace.traceEnd(Trace.TRACE_TAG_ACTIVITY_MANAGE
                   break;
```

Trace.traceBegin需要与Trace.traceEnd配套使用，用于产生可由Systrace工具处理的输入数据。Systrace可以帮助开发者分析应用程序

或系统进程的执行时间，并最终得出描述Android系统运行情况的HTML报告。函数handleBindApplication中与OpenGL Trace相关的代码如下：

```
    private void handleBindApplication(AppBindData data) {…
        if (data.enableOpenGlTrace) {
            GLUtils.setTracingLevel(1);
        }
```

GLUtils是Android API与OpengGL ES之间沟通的“桥梁”，其提供的接口大多需要本地层函数来支撑，包括setTracingLevel。这个函数的Native实现如下：

```
/*frameworks/base/core/jni/android/opengl/util.cpp*/
extern void setGLDebugLevel(int level);
void setTracingLevel(JNIEnv *env, jclass clazz, jint level)
{
    setGLDebugLevel(level);
}
```

函数setGLDebugLevel的实现在egl中：

```
/*frameworks/native/opengl/libs/EGL/egl.cpp*/
void EGLAPI setGLDebugLevel(int level) {
    setEGLDebugLevel(level);
}
```

这个函数所提供的功能是帮助程序修改自身的调试等级。不过要特别注意的是，函数setEGLDebugLevel只是改变了Debug Level的值（具体来说，是为sEGLDebugLevel这个变量赋予新的数值），真正生效则要等到initEglDebugLevel（如果程序还没有完成初始化）或者eglSwapBuffers被调用的时候。以后者为例，eglSwapBuffers在执行时会首先判断当前是否开启了调试模式：

```
/*frameworks/native/opengl/libs/egl/eglApi.cpp*/
EGLBoolean eglSwapBuffers(EGLDisplay dpy, EGLSurface draw)
{
    ATRACE_CALL();
    …
#if EGL_TRACE
    gl_hooks_t const *trace_hooks = getGLTraceThreadSpecific();
    if (getEGLDebugLevel() > 0) {//当前是否将Debug Level设置为1
        if (trace_hooks == NULL) {
```

```
            if (**GLTrace_start**() < 0) {//稍后我们分析这个函数
                ALOGE("Disabling Tracer for OpenGL ES");
                setEGLDebugLevel(0);//无法正常开启追踪，需要将其关闭
            } else {
                // switch over to the trace version of hooks
                EGLContext ctx = egl_tls_t::getContext();/*转换Cor
                                                       指向带调试信
                egl_context_t * const c = get_context(ctx);
                if (c) {
                    setGLHooksThreadSpecific(c->cnx->hooks[c->ver
                    GLTrace_eglMakeCurrent(c->version, c->cnx->ho
                }
            }
        }
        GLTrace_eglSwapBuffers(dpy, draw);
    } else if (trace_hooks != NULL) {
       …
    }
#endif
    …
    return s->cnx->egl.eglSwapBuffers(dp->disp.dpy, s->surface);
}
```

假如Debug Level的值被设置为1，那么egl在swap buffer时会调用GLTrace_start来启动OpenGL命令流的跟踪。简单来讲，就是在上述的else分支中将用户对egl的调用从以前单纯的egl接口，转化为带调试信息的GLTrace_egl接口（OpenGL的接口也是类似的）。举个例子来说明，经过GLTrace的特别Hook处理后的eglSwapBuffers接口变为：

```
/*frameworks/native/opengl/libs/gles_trace/src/Gltrace_egl.cpp*/
void GLTrace_eglSwapBuffers(void* /*dpy*/, void* /*draw*/) {
    GLMessage glmessage;
    GLTraceContext *glContext = getGLTraceContext();
    glmessage.set_context_id(glContext->getId());
    glmessage.set_function(GLMessage::eglSwapBuffers);
    if (glContext->getGlobalTraceState()->shouldCollectFbOnEglSwa
        // read FB0 since that is what is displayed on the screen
        fixup_addFBContents(glContext, &glmessage, FB0);
    }
    // set start time and duration
    glmessage.set_start_time(systemTime());
    glmessage.set_duration(0);
    glContext->traceGLMessage(&glmessage);
}
```

其中glmessage用于收集需要向PC客户端反馈的信息，包括了

context id、函数名、开始时间等。当然，egl提供的几个接口比较特殊。如果是“opengl”类型的接口，那么它们在被Hook后仍需要调用原始的实现。换句话说，GLTrace只是在原有内容的“头部”和“尾部”添加了自己需要的信息而已，并不改变原先的运行属性。

最后我们再来看下GLTrace_start中具体是如何启动一个监听Server的：

```
/*frameworks/native/opengl/libs/GLES_trace/src/gltrace_eglapi.cpp
int GLTrace_start() {
    int status = 0;
    int clientSocket = -1;
    TCPStream *stream = NULL;
    pthread_mutex_lock(&sGlTraceStateLock);
    if (sGlTraceInProgress) {
        goto done;
    }
    char udsName[PROPERTY_VALUE_MAX];
    property_get("debug.egl.debug_portname", udsName, "gltrace");
                                        指定的debug_portname，否则采用默认值
    clientSocket = gltrace::acceptClientConnection(udsName);//启动
    …
    sGlTraceInProgress = 1;//进入跟踪状态
    // create communication channel to the host
    stream = new TCPStream(clientSocket);
    // initialize tracing state
    sGLTraceState = new GLTraceState(stream);
    pthread_create(&sReceiveThreadId, NULL, commandReceiveTask, s
    /*建立与PC端的数据传输通道*/
done:
    pthread_mutex_unlock(&sGlTraceStateLock);
    return status;
}
```

我们知道，用户在使用GLTracer收集数据的过程中是可以动态更改采集选项的，比如enable/disable “Read back framebuffer 0 on eglSwapBuffers()” “Read back currently bound framebuffer On glDraw*()”等。这是因为egl会通过commandReceiveTask不断监听用户传递过来的命令，并做好实时的更新和调整。这样就建立起被监测程序(Server)和位于PC端的GLTracer间的通信渠道了，后续只需要在这条管道上不停地收发信息就可以了。

下面是本小节所阐述的各个组件间的交互流程图，如图17-14所

示。由于整个实现过程涉及的范围较广，我们特别将其拆分为两个部分，以方便大家阅读。

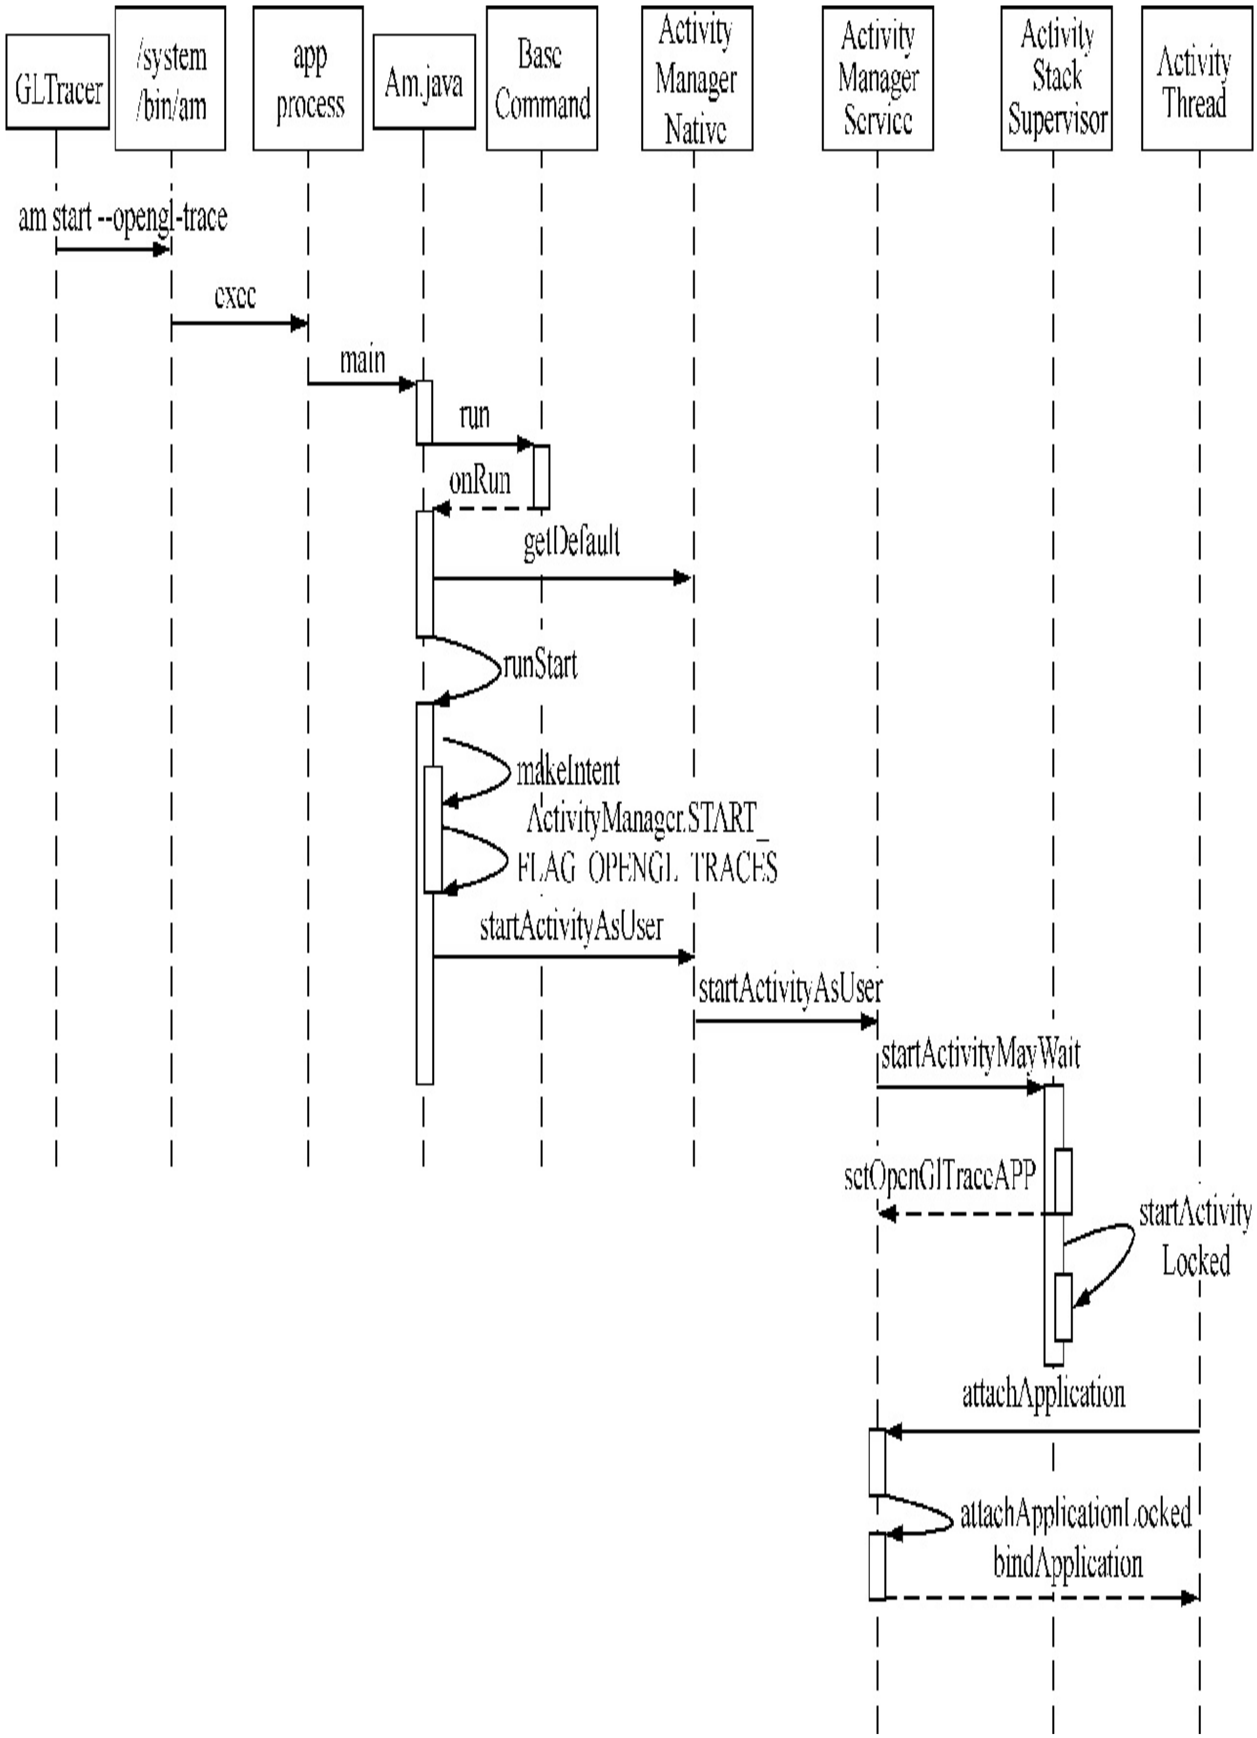
GLTracer
/system
/bin/am
app
process
Am.java
Base
Command
Activity
Manager
Native
Activity
Manager
Service
Activity
Stack
Supervisor
Activity
Thread
am start --opengl-trace
exec
main
run
onRun
getDefault
runStart
makeIntent
ActivityManager.START_
FLAG_OPENGL_TRACES
startActivityAsUser
startActivityAsUser
startActivityMayWait
setOpenGlTraceAPP
startActivity
Locked
attachApplication
attachApplicationLocked
bindApplication

▲图17-14 OpenGL命令流跟踪的处理流程（1/2）

ActivityThread在收到bindApplication请求后的处理，如图17-15所示。

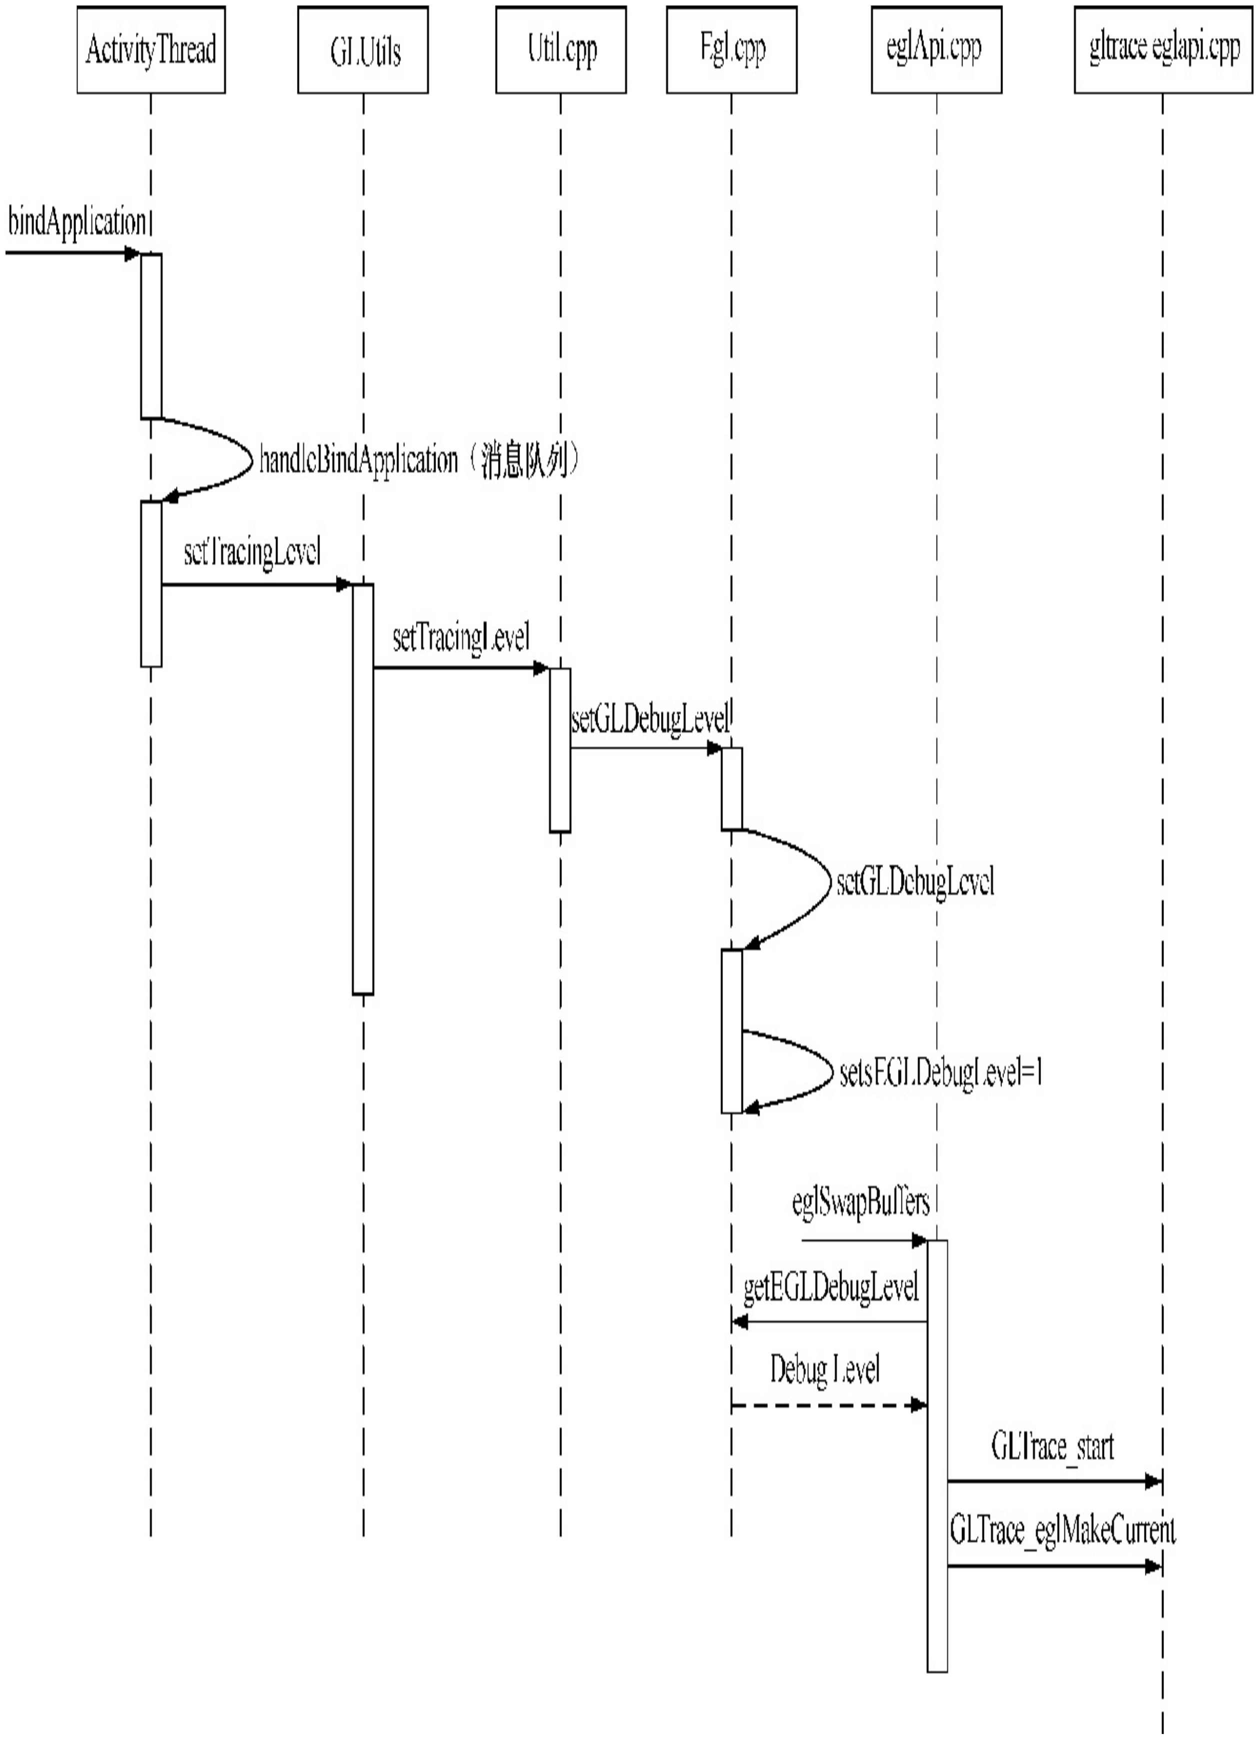

ActivityThread
GLUtils
Util.cpp
Egl.cpp
eglApi.cpp
gltrace eglapi.cpp
bindApplication
handleBindApplication（消息队列）
setTracingLevel
setTracingLevel
setGLDebugLevel
setGLDebugLevel
setsEGLDebugLevel=1
eglSwapBuffers
getEGLDebugLevel
DebugLevel
GLTrace_start
GLTrace_eglMakeCurrent

▲图17-15 OpenGL命令流跟踪的处理流程（2/2）

第18章 “系统的UI”——SystemUI

从名称来理解，SystemUI是指“系统的UI”。Android系统的版本更新频率非常快，且每次改版的力度也很大。典型的例子就是SystemUI，它是直到后期版本才出现的一个概念——SystemUI以应用程序（它是一个标准的APK）的形式提供了系统UI界面的统一管理方案。

那么，属于Android系统的UI元素有哪些？

首先映入脑海的应该是状态通知栏。没错，这的确是SystemUI的重点之一，不过显然不是它的全部组成元素。Google希望能在一套代码中同时支持Phone和Tablet这两种产品类别——作为系统“门面”的SystemUI在设计时必然要重点考虑这一点。

所以，本章我们主要分析以下几个问题：

- SystemUI包含哪些元素；
- SystemUI中的元素特点和内部实现；
- SystemUI是如何做到兼容多种产品的。

18.1 SystemUI的组成元素

System Bars：

我们借用Android官网中的一张图片来让读者有个直观的印象，如图18-1所示。

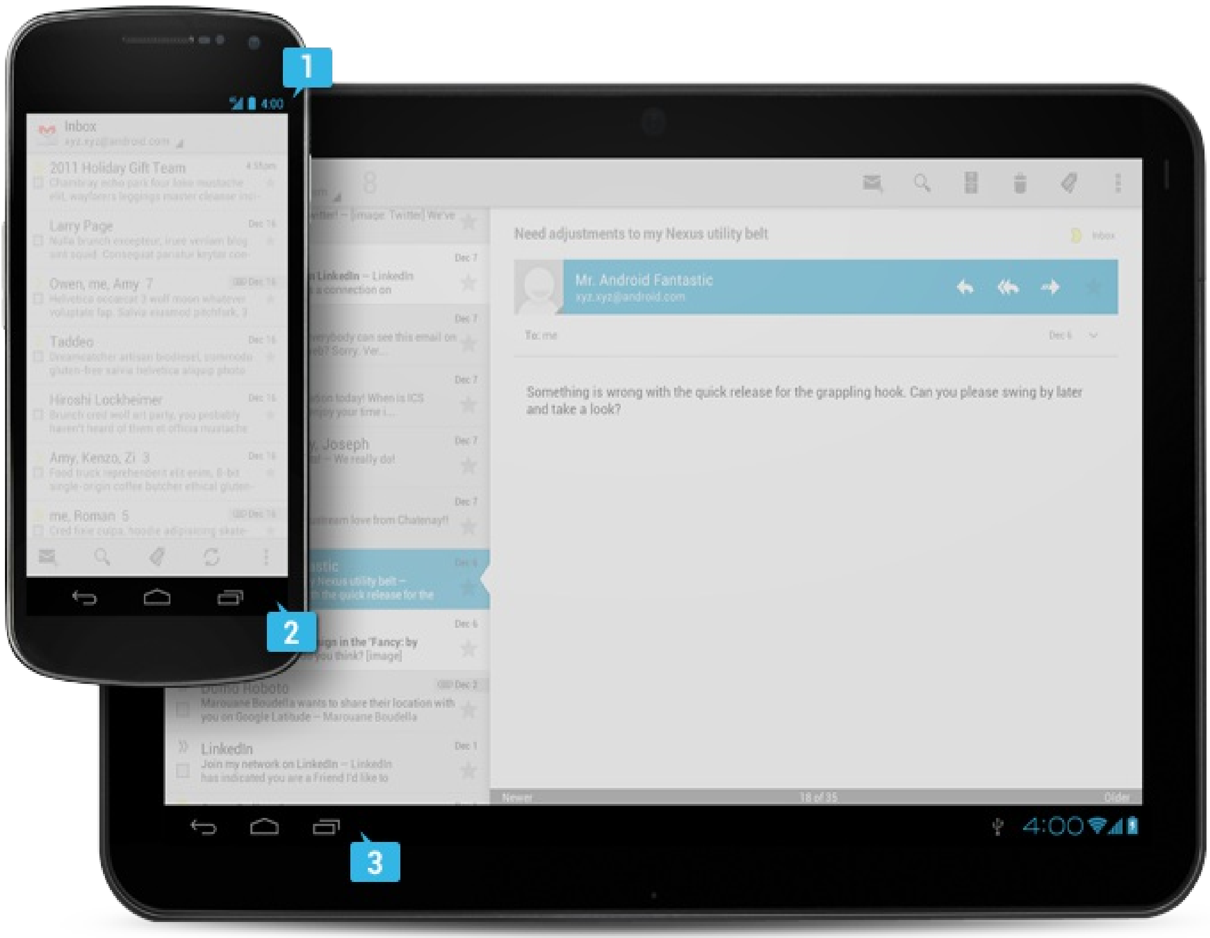

▲图18-1　System Bars

可以看到，System Bars为了同时支持Phone和Tablet，共分为3种。

- Status Bar

这是大家最熟悉的状态通知栏，它位于手机屏幕的上方位置，而且是一直存在的（除非应用程序主动设置了隐藏）。为了方便使用，它被大致划分为左右两部分（准确来讲不止两部分，下一小节会有分析）。其中左边用于通知信息的显示（比如接收到一条短信，会有相应的图标指示）；右边则是全局的设备状态，如时间、电池电量、信号强度等。为了互不干扰，左右两边的图标是沿不同的方向不断扩展的（左半部分“从左到右”增加图标，另一边则恰好相反）。当拖住Status Bar向下拉时，可以显示出通知栏。

- Navigation Bar

  这是Android 4.0以后才加入的元素。目的有两个：

- 为那些没有物理按键的设备提供便利；

- 2.3和以前版本的应用程序多半是需要Menu键的，Navigation Bar可以提供Home、Back、Recents和Menu（一般是常按Recents出现Menu）来满足它们的要求。

- Combined Bar

这是专门为Tablet设计的一种系统栏形式。它和Phone产品的最大区别在于，Phone通常是竖屏，而Tablet是横屏。这也意味着手机设备的高度相比于Tablet比较宽裕，因此后者不太适合同时显示两条Bar。而又因其宽度值较大，我们完全可以利用这个特点来兼容Phone中的所有导航和状态栏功能，于是就出现了Combined Bar（如图18-1标注“3”的部分）。

Notifications：

再来看看通知栏的样子，如图18-2所示的图片也来自于Android官网。左边是通知栏显示若干条目时的样式，右边则是对条目进行删除（将条目向左或向右滑动）时的效果。

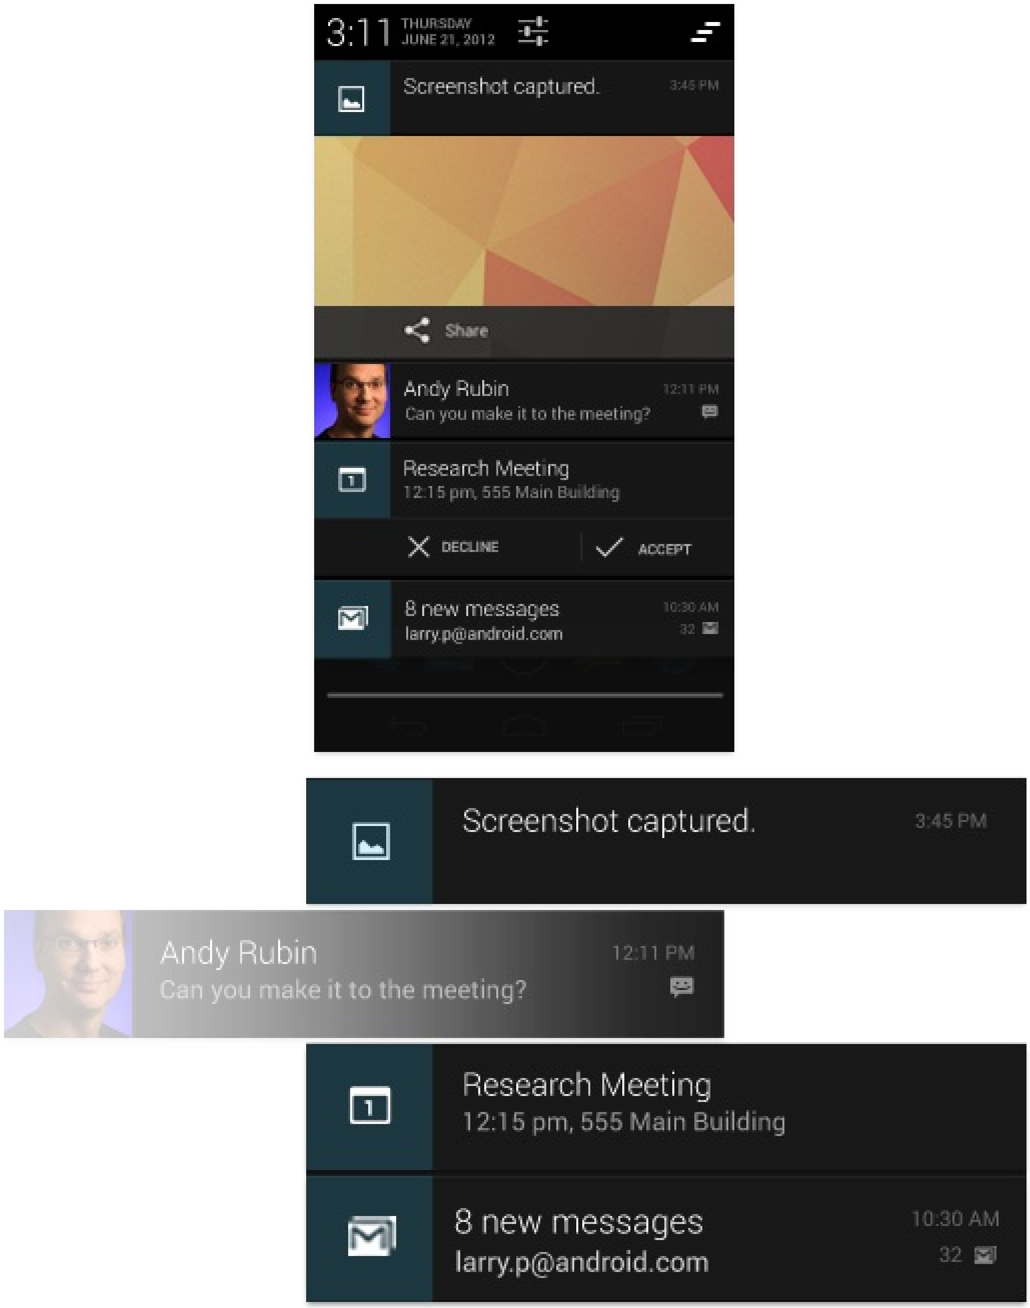

▲图18-2 Notifications

相信读者对通知栏也不会陌生，它一直存在于Android的各发行版本中。不过后期版本中还是加入了不少新特性。

- 通知信息格式可定制

早期版本是两行显示，即第一行用于标题，第二行则是内容。但这并不是必需的，你可以根据需求来做更改。

- 支持更多手势操作

比如你可以通过向左或者向右滑动某个条目来删除它。

- 支持更多常用功能

如上图所示的第一个条目，它表明屏幕的“截图操作”已经完成。用户可以通过点击条目来进行分享等操作。

其他：

除此之外，SystemUI还实现了很多实用的系统功能，如“最近运行的应用程序”、ScreenShot截屏、壁纸（后面小节有专门介绍）等。

18.2 SystemUI的实现

了解了SystemUI的组成元素后，本节以StatusBar为例，来分析下Android系统具体是如何实现它们的。

相关代码分为两部分，即：

- Service部分

代码路径：frameworks/base/services/java/com/android/server。

- 应用部分

代码路径：frameworks/base/packages/SystemUI。

从SystemUI目录中的文件可以看出，它是一个标准的应用程序。而通常分析一个应用程序的入口点有两个。

入口一：AndroidManifest.xml

AndroidManifest文件的功能有点类似于一本书的目录，可以很清楚地了解到它的章节架构、章节标题以及每个章节的主要内容。下面来看看SystemUI的“目录”，如下所示：

```
…
<applicationandroid:persistent="true"android:allowClearUserData="
android:allowBackup="false"android:hardwareAccelerated="true"andr
 <service android:name="SystemUIService"android:exported="true"/>
          /*SystemUIService是我们分析的重点，状态栏等系统UI实现都是在这里
 <service android:name=".screenshot.TakeScreenshotService"
   android:process=":screenshot" android:exported="false" />/*由此
                                        截屏操作。有兴趣的读者可以自己
 <receiver android:name=".BootReceiver"androidprv:primaryUserOnly
                            不过这里启动的是LoadAverageService，而不是
  <intent-filter>
   <action android:name="android.intent.action.BOOT_COMPLETED" />
  </intent-filter>
</receiver>
…
```

从上面的文件可以看出SystemUI可谓“包罗万象”。

入口二：Layout

第2个分析应用程序的入口就是布局文件。如果说上面的AndroidManifest是一本书的“目录”，那么布局文件则是它的子目录——揭示了每一章节更详细的内容。

通过AndroidManfiest我们知道SystemUIService是整个系统UI的“载体”，所以接下来将根据这一线索来把整个代码流程“串”起来。和其他很多系统服务一样，SystemUIService也是在SystemServer中启动的。具体而言，SystemServer会在适当的时机通知ActivityManagerService“系统已经就绪（systemReady），可以进一步运行第三方模块了”——这其中就包括将由startServiceAsUser启动的SystemUIService。

SystemUIService继承了标准的Service组件，因而必须重载onCreate接口：

```
/*frameworks/base/packages/systemui/src/com/android/systemui/Syst
    public void onCreate() {…
        IWindowManager wm = WindowManagerGlobal.getWindowManagerS
        try {
           SERVICES[0] = wm.hasSystemNavBar()? R.string.config_sy
           : R.string.config_statusBarComponent;//是StatusBar还是S
        } catch (RemoteException e) {
            Slog.w(TAG, "Failing checking whether status bar can
        }
        final int N = SERVICES.length;
        mServices = new SystemUI[N];
        for (int i=0; i<N; i++) {
            Class cl = chooseClass(SERVICES[i]);
            Slog.d(TAG, "loading: " + cl);
            try {
                mServices[i] = (SystemUI)cl.newInstance();
            } …
            mServices[i].mContext = this;
            Slog.d(TAG, "running: " + mServices[i]);
            mServices[i].start();//mServices中的每个元素都继承自Syste
        }
    }
```

SERVICES是一个object数组，它的初始值如下所示：

```
final Object[] SERVICES = new Object[] {
        0, // system bar or status bar, filled in below.
        com.android.systemui.power.PowerUI.class,
        com.android.systemui.media.RingtonePlayer.class,
        com.android.systemui.settings.SettingsUI.class,
    };
```

其中，SERVICES[0]在初始化时没有赋值。它将根据hasSystemNavBar的执行结果来决定是用systemBar还是statusBar。上面这段代码首先取出SERVICES数组中的class名，然后分别实例化它们，最后调用start接口统一启动。因此，每一个系统ui元素（包括statusBar，PowerUI等）都必须继承自SystemUI这个抽象类，并重载其中的start方法。这是一种比较灵活的编程方式，它允许我们在后期对系统UI元素进行轻松的扩展或者删除。

函数hasSystemNavBar做了哪些判断来对statusBar和systemBar进行取舍呢？

根据前面章节学习到的知识，WindowManager的真正实现体是WindowManagerService。所以：

```
     /*frameworks/base/services/java/com/android/server/wm/Window
     public boolean hasSystemNavBar() {
        return mPolicy.hasSystemNavBar();
    }
```

我们知道，Policy是Android中定义UI行为的一个“规范”。比如有没有Navigation Bar，WindowLayer如何排布等。以PhoneWindowManager为例，它判断当前系统是否需要导航条的关键源码如下（为了帮助大家更好地理解处理流程，我们假设设备的分辨率是800*480，屏幕密度为ldpi）：

```
/*frameworks/base/policy/src/com/android/internal/policy/impl/Pho
       int shortSizeDp = shortSize*DisplayMetrics.DENSITY_DEFAULT
        /*在这个场景中，shortSize=480，DENSITY_DEFAULT=160，density
        shortSizeDp = 640*/

        if (shortSizeDp < 600) {//在这个场景中不成立
            mHasSystemNavBar = false;
            mNavigationBarCanMove = true;
        } else if (shortSizeDp < 720) {/*本场景属于这一分支*/
            mHasSystemNavBar = false;
```

```
            mNavigationBarCanMove = false;
        }
        if (!mHasSystemNavBar) {//进一步判断是否有Navigation Bar
            …
        } else {
            mHasNavigationBar = false;
        }
```

由上面的代码段可知，系统将分为3种判决情况。

- 0-599dp

说明该设备是——“phone”，并且带有单独的StatusBar和NavigationBar。

- 600-719dp

说明该设备是——“phone”，并且可以适当修正UI以适应大屏幕。

- 720dp以上

说明该设备是——“tablet”，并且带有Combined Status&Navigation Bar。

所以在这个场景中，经过上面的判决后mHasSystemNavBar为false。换句话说，对于分辨率800*480且密度为ldpi的屏幕，它的SERVICES[0]对应的class类名是R.string.config_statusBar Component
即“com.android.systemui.statusbar.phone.PhoneStatusBar”。下面以PhoneStatusBar为例来看看它的创建过程及具体样式：

```
     /*frameworks/base/packages/systemui/src/com/android/systemui
     PhoneStatusBar.java*/
    public void start() {
        mDisplay = ((WindowManager)mContext.getSystemService(Cont
                .getDefaultDisplay();/*mDisplay记录了当前默认显示屏的
        …
        super.start();// 关键语句，下面我们会重点介绍
        addNavigationBar();/*不是所有Phone都需要Navigation Bar。比如
                                     键，这种情况下如果一直在屏幕上显示导航条反而
        …
```

```
    }
```

PhoneStatusBar的“父类”是BaseStatusBar，很多框架性的操作都是在这里面完成的（但UI界面的具体描述还是会通过回调PhoneStatusBar中的方法来确定）：

```
/*frameworks/base/packages/systemui/src/com/android/systemui/s
usBar.java*/
public void start() {…
   mBarService = IStatusBarService.Stub.asInterface(
           ServiceManager.getService(Context.STATUS_BAR_SERVIC
   // Connect in to the status bar manager service
   StatusBarIconList iconList = new StatusBarIconList();//状态柞
   ArrayList<IBinder> notificationKeys = new ArrayList<IBinder
   ArrayList<StatusBarNotification> notifications = new ArrayL
   mCommandQueue = new CommandQueue(this, iconList);
   int[] switches = new int[7];
   ArrayList<IBinder> binders = new ArrayList<IBinder>();
   try {
       mBarService.registerStatusBar(mCommandQueue,iconList,no
              notifications,switches, binders); /*经过一系列对象
                             StatusBarService进行注册。这里涉及跨进
                             参数都是继承自Parcelable的*/
   } catch (RemoteException ex) {
       // If the system process isn't there we're doomed anywa
   }
   createAndAddWindows(); /*这是真正将Status Bar显示出来的地方*/
   …
}
```

好不容易快到“水落石出”的时候了，但是上面这段代码却又杀出一个“程咬金”——StatusBarService。相信读者会有这样的疑问：既然SystemUI这个应用程序中已经有StatusBar了，为什么又需要StatusBarService，是否多此一举？

先来看看StatusBarService是在哪里启动的。直觉告诉我们应该是在SystemServer中（读者也可以通过STATUS_BAR_SERVICE对应的关键字来查找是谁向ServiceManager注册了这个名字）：

```
/*frameworks/base/services/java/com/android/server/SystemSer
try {
      Slog.i(TAG, "Status Bar");
      statusBar = new StatusBarManagerService(context, wm);
      实现类叫做StatusBarManagerService*/
```

```
        ServiceManager.addService(Context.STATUS_BAR_SERVICE,
    } catch (Throwable e) {
         reportWtf("starting StatusBarManagerService", e);
    }
```

现在可以进一步分析StatusBarManagerService的实现了。针对上面BaseStatusBar中调用的注册操作：

```
public void registerStatusBar(IStatusBar bar, StatusBarIconList i
                    notificationKeys,List<StatusBarNotification>
                                      int switches[], List<IBinde
        enforceStatusBarService();
        mBar = bar;
        synchronized (mIcons) {
           iconList.copyFrom(mIcons); /*复制Icon列表，注意方向是从Sta
                                      BaseStatusBar*/
        }
        synchronized (mNotifications) {
           for (Map.Entry<IBinder,StatusBarNotification> e: mNoti
           {
               notificationKeys.add(e.getKey());
               notifications.add(e.getValue());/*和Icon列表类似，方
                                      到BaseStatusBar*/
            }
        }
        …
    }
```

由上面这段代码可以看出，registerStatusBar有两个作用：

其一，为新启动的SystemUI应用中的StatusBar赋予当前系统的真实值（比如有多少需要显示的图标）。其二，通过成员变量mBar记录下IStatusBar对象——它在SystemUI中对应的是CommandQueue。

那么，StatusBarManagerService是不是发挥了后台存储和管理数据（状态栏图标信息）的作用呢？稍后揭晓。

我们再回到BaseStatusBar。向StatusBarManagerService注册完成后，它会执行如下语句。

```
createAndAddWindows();
```

BaseStatusBar中的这个方法是抽象的，因而其子类

PhoneStatusBar必须要重载它：

```
/*frameworks/base/packages/systemui/src/com/android/systemui
oneStatusBar.java*/
public void createAndAddWindows() {
    addStatusBarWindow();
}
private void addStatusBarWindow() {
    final int height = getStatusBarHeight();/*首先获取StatusBa
                    过com.android.internal.R.dimen.status_ba
                    开发人员如果需要更改StatusBar高度的话，可以考虑
    final WindowManager.LayoutParams lp = new WindowManager.L
            ViewGroup.LayoutParams.MATCH_PARENT, /*宽度是MATCH
            height, //高度值是可定制的
            WindowManager.LayoutParams.TYPE_STATUS_BAR, /*指定
            WindowManager.LayoutParams.FLAG_NOT_FOCUSABLE|
              WindowManager.LayoutParams.FLAG_TOUCHABLE_WHEN_
               | WindowManager.LayoutParams.FLAG_SPLIT_TOUCH,
               /*设置flag, 下面还会加上硬件加速属性*/
            PixelFormat.TRANSLUCENT/*半透明的*/);

    lp.flags |=windowManager.LayoutParams.FLAG_HARDWARE_ACCEL
    lp.gravity = getStatusBarGravity();/*设置Gravity属性，默认值
    |Gravity.FILL_HORIZONTAL,所以StatusBar是在屏幕上方*/
    lp.setTitle("StatusBar"); //标题
    lp.packageName = mContext.getPackageName();
    makeStatusBarView(); //下面会详细介绍
    mWindowManager.addView(mStatusBarWindow, lp); /*将一切就绪的
                        WindowManager中。请参见本书显示系统章节
}
```

从makeStatusBarView这个函数名可以推断出，StatusBarView会被创建并且初始化。先来了解下两个重要的变量。

- mStatusBarWindow

这是一个StatusBarWindowView类对象，同时我们通过addView传给WindowManager的也是这个变量——说明它很可能包含了StatusBarView。

- mStatusBarView

这就是makeStatusBarView需要操作的对象。

接着来具体看看代码，只节选重点部分：

```
/*frameworks/base/packages/systemui/src/com/android/systemui/stat
StatusBar.java*/
    protected PhoneStatusBarView makeStatusBarView() {…
       mStatusBarWindow = (StatusBarWindowView) View.inflate(con
       status_bar, null);
       mStatusBarWindow.mService = this; //mService其实指的是Phone
       mStatusBarWindow.setOnTouchListener(new View.OnTouchListe
           @Override
           public boolean onTouch(View v, MotionEvent event) {
               if (event.getAction() == MotionEvent.ACTION_DOWN)
                   if (mExpandedVisible) {
                      animateCollapsePanels ();//通知栏的"下拉展开"
                   }
               }
               return mStatusBarWindow.onTouchEvent(event);
           }});
       mStatusBarView =(PhoneStatusBarView)mStatusBarWindow.find
       mStatusBarView.setBar(this); /*状态栏出场了*/
       …
       mNotificationPanel = (NotificationPanelView) mStatusBarWi
                                findViewById(R.id. notification
     mNotificationPanel.setStatusBar(this); /*通知栏也很关键，只不过
       /*从下面开始将利用mStatusBarView为PhoneStatusBar中的众多内部变
       …
       try {
           boolean showNav = mWindowManagerService.hasNavigation
           if (showNav) {
               mNavigationBarView = (NavigationBarView) View.inf
                                    R.layout. navigation_ bar, n
                                    /*Navigation Bar对应的layout。
               …
           }
       } catch (RemoteException ex) {
           /*Android中的不少代码在捕捉异常时，很常见的一种处理就是"听天由
       }
       /*接下来通过findViewById从mStatusBarView中获取StatusIcons、No
          ClearButton等一系列按键。我们将会在StatusBar布局文件中做统一分
       …
       /*最后动态注册需要接收的广播，比如系统设置改变，屏幕关闭等*/
       IntentFilter filter = new IntentFilter();
       filter.addAction(Intent.ACTION_CONFIGURATION_CHANGED);
       filter.addAction(Intent.ACTION_CLOSE_SYSTEM_DIALOGS);
       …
       context.registerReceiver(mBroadcastReceiver, filter);…
       return mStatusBarView;//注意最终返回值是mStatusBarWindow的子V
```

}

变量mStatuBarWindow来源于super_status_bar布局。它本质上还是一个FrameLayout，包含的元素也很简单，就是status_bar和status_bar_expanded两个布局（SystemUI的资源目录下有多种带不同资源标签的Layout，系统会根据设备的具体属性来做出合理的选择）。关于资源的最佳匹配过程，可以参见前面资源适配章节。

函数hasNavigationBar用于决定是否需要导航条。

（1）如果是Tablet，就肯定不需要。

（2）如果是Phone，那么还要根据屏幕属性、是否有按键值以及用户是否有特别配置等一系列因素，来最终确定NavigationBar存在与否。

最后来总结一下makeStatusBarView的工作。

（1）通过inflate，得到mStatusBarWindow，对应的是super_status_bar布局。

（2）super_status_bar包含了status_bar和status_bar_expanded两个子布局。前者对应的是状态栏mStatusBarView，后者其实就是通知栏mNotificationPanel。

（3）为status_bar中的众多元素（按键、背景等）进行初始化。

（4）最终的返回值是mStatusBarView。然后利用WindowManager的addView接口将mStatus- BarWindow（注意：不是mStatusBarView）添加进窗口系统中。接下来的主动权就转交给WindowManager，详见本书显示系统章节对WindowManager的分析。

由此可见，这个函数如果称之为makeStatusBarWindow可能会更贴切些。

这样我们就把StatusBar，Notification和NavigationBar的调用流程“串”起来了。图18-3是整个调用流程图，读者可以参考一下。

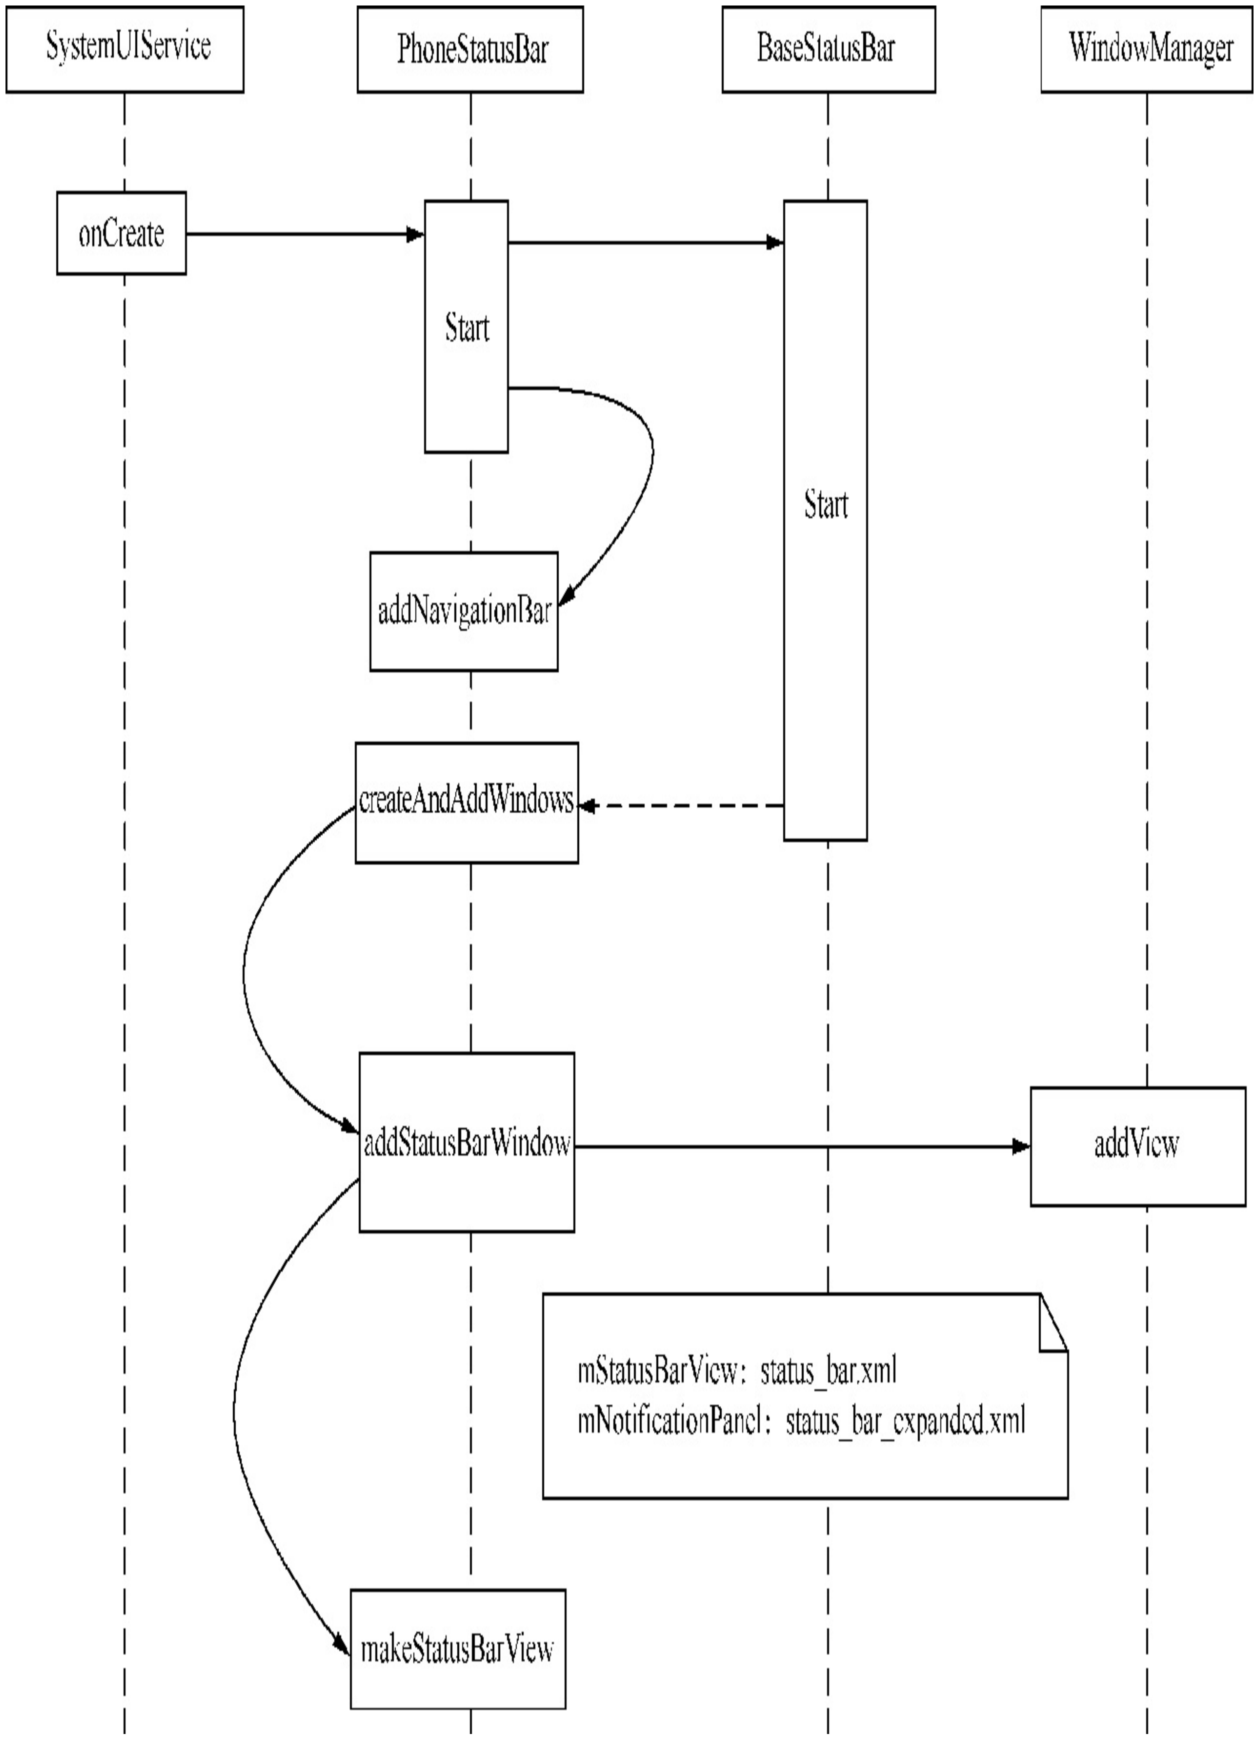
SystemUIService
PhoneStatusBar
BaseStatusBar
WindowManager
onCreate
Start
Start
addNavigationBar
createAndAddWindows
addStatusBarWindow
addView
mStatusBarView: status_bar.xml
mNotificationPanel: status_bar_expanded.xml
makeStatusBarView

▲图18-3　SystemUI（StatusBar）的显示流程图

最后我们来分析下StatusBar的layout布局样式——这个占位不大的显示条可谓“麻雀虽小，五脏俱全”。

我们知道，StatusBarWindow的默认高度是com.android.internal.R.dimen.status_bar_height，即：

```
<dimen name="status_bar_height">25dip</dimen>
```

所以StatusBar的高度默认情况下不超过25dip，当然开发者可以根据需求自行更改。

StatusBar对应的layout文件是status_bar.xml，具体如下所示：

```
/*frameworks/base/packages/SystemUI/res/layout/status_bar.xml*/
<com.android.systemui.statusbar.phone.PhoneStatusBarView
/*对应PhoneStatusBarView类(继承自FrameLayout)，也就是上面代码中的mStat
    android:id="@+id/status_bar"android:background="@drawable/sta
    android:focusable="true"android:descendantFocusability="after
    android:fitsSystemWindows="true">
<ImageViewandroid:id="@+id/notification_lights_out"…android:visib
<LinearLayout android:id="@+id/icons"android:layout_width="match_
       android:layout_height="match_parent"android:orientation="h

<LinearLayoutandroid:id="@+id/notification_icon_area"
         android:layout_width="0dip"android:layout_height="match_
         android:layout_weight="1" /*4种icon中只有notification设置了
                                    多的剩余空间*/
         android:orientation="horizontal">/*通知栏图标在最左面。初始宽
                                           任何图标*/
<com.android.systemui.statusbar.StatusBarIconView android:id="@+i
                                       /*当notificationIcons满了以后
             android:layout_width="@dimen/status_bar_icon_size" /
             android:layout_height="match_parent"android:src="@dr
             android:visibility="gone"/*正常情况下是不需要显示的*/
             />
<com.android.systemui.statusbar.phone.IconMerger android:id="@+id

             android:layout_width="match_parent"android:layout_he
             android:layout_alignParentLeft="true" /*从左到右*/
             android:gravity="center_vertical" /*icon按垂直方向中间对
             android:orientation="horizontal"/>
</LinearLayout>
```

```
<LinearLayout android:id="@+id/statusIcons" /*状态图标*/
              android:layout_width="wrap_content" /*注意和notifica
              android:layout_height="match_parent"android:gravity

              android:orientation="horizontal"/>
<LinearLayout
              android:id="@+id/signal_battery_cluster" /*用于信号和
              android:layout_width="wrap_content"android:layout_h
              android:paddingLeft="2dp"android:orientation="horiz
              android:gravity="center">
<include layout="@layout/signal_cluster_view"
           /*信号指示图标的集合。称为cluster，是因为包括2G/3G网络信号，以
              BlueTooth等图标都在这里集中显示*/
              android:id="@+id/signal_cluster"
              android:layout_width="wrap_content"android:layout_h
<ImageViewandroid:id="@+id/battery" /*电池图标区域。比较单一，通常就是
              android:layout_height="wrap_content"android:layout_
              android:paddingLeft="4dip"/>
</LinearLayout>
<com.android.systemui.statusbar.policy.Clockandroid:id="@+id/cloc
          /*时间和闹钟区域。如果当前设备没有设置任何闹钟，则只有时间显示*/
          android:textAppearance="@style/TextAppearance.StatusBar
          android:layout_width="wrap_content"android:layout_heigh
          android:singleLine="true"android:paddingLeft="6dip"andr
center_vertical|left"/>
</LinearLayout>
<LinearLayout android:id="@+id/ticker"/*注解3*/
        …
</com.android.systemui.statusbar.phone.PhoneStatusBarView>
```

注解1：icons其实是水平方向的LinearLayout，是下面4种icon的“容器”。

- notification icons：通知图标。
- status icons：状态图标。
- signal_battery cluster：信号/电池指示。
- clock：时钟。

注解2：通知栏图标。IconMerger是一个扩展了的LinearLayout，其中加入了不少额外的管理。比如计算通知栏的空间是否已满，从而控制moreIcon的显示。

注解3：Ticker用于“提示信息”的临时显示。它在显示时占满整

个状态栏，并在一定时间后自动消失（会有“出现和消失”的动画效果）。比如我们插入SD卡时，Ticker上会提示“SD卡设备已插入”。这部分的布局样式和icons类似，请读者自行分析。

图18-4概括了status_bar中icons部分的布局，供读者参考理解。

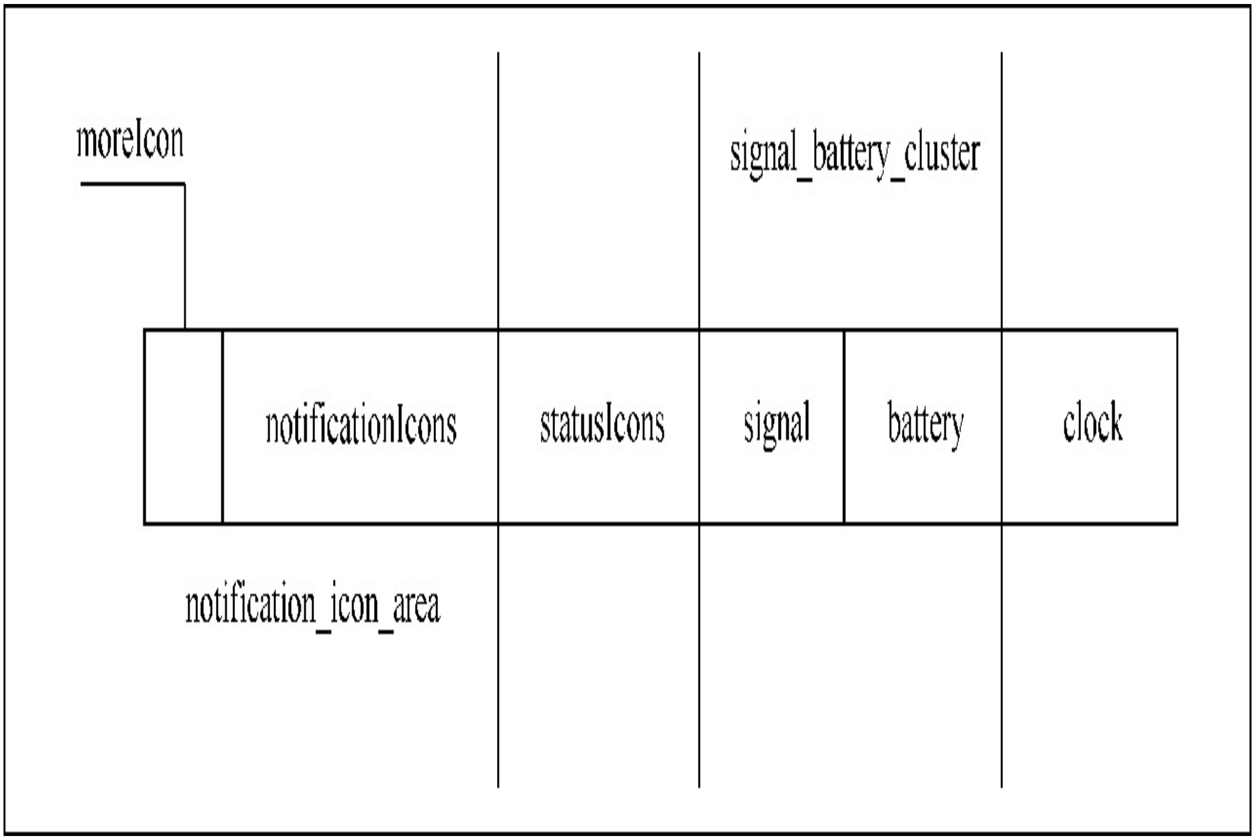

▲图18-4　icons部分的layout布局

18.3 Android壁纸资源——WallpaperService

除了前面讲解的状态栏、通知栏外，壁纸也属于SystemUI管理的一个重点。在Android系统中，用户可以从设备内部或者外存储器（比如SD卡中）中选取图片资源作为壁纸。另外，系统还支持动态壁纸的显示。动态壁纸的基本原理是随着时间的迁移而切换显示不同的图片资源，属于Android的特色功能之一。

从实现角度来讲，可以把壁纸资源分为两类。

- 静态图片

比如jpg、png等类型的图片。用户可以直接把它们设置为壁纸。

- APK应用程序

还有的壁纸下载后是APK形式，用户需要安装以后才能正常使用（动态壁纸通常就是通过这种方式提供的）。不过这并不是说静态的图片不需要APK的支持——事实上不论静态、动态壁纸的显示都是由APK完成的，只不过前者借助于系统内部提供的APK即可，而后者的“动态多样性”决定了其需要借助于额外的APK来实现。

不管是哪种方式，都要遵循Android系统的壁纸机制才能正常工作。壁纸管理系统主要包括以下几个方面。

- WallpaperManagerService（WPMS）

它是壁纸机制的“大总管”，静态、动态壁纸都是在这里统一调度的。

- WallpaperService（WPS）

WPS继承了标准的Service组件，因而它一定会实现onCreate、onDestroy、onBind等一系列方法。此外它还包含了一个重要的嵌套类engine，我们在后面会做详细讲解。WPS是静态、动态壁纸的基类，代表了作为“壁纸”所应该具有的一切属性。

- ImageWallpaper（IWP）

从名称可以看出，它是静态壁纸的实现类，而且一定是继承自上面的WPS，如图18-5所示。本节接下来主要以静态壁纸的分析为主。

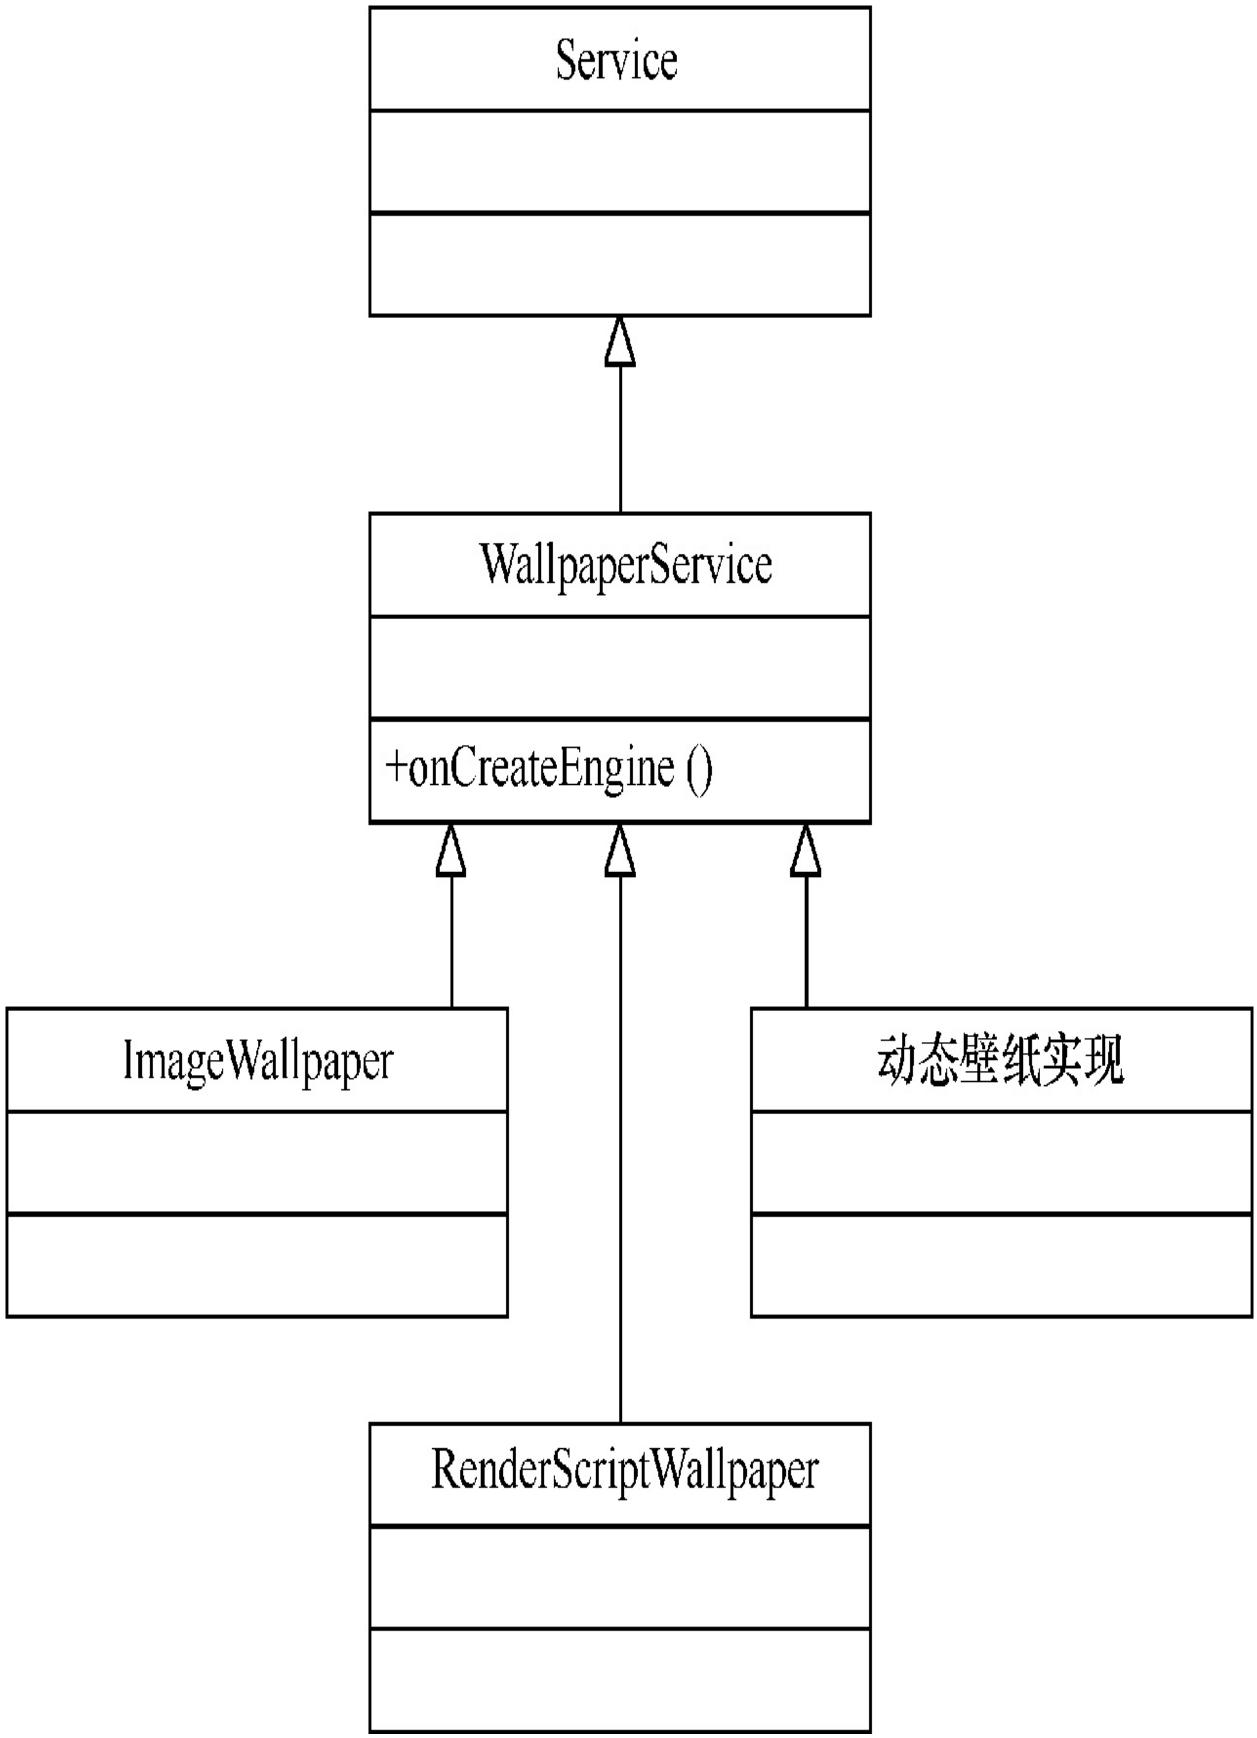
Service
WallpaperService
+onCreateEngine ()
ImageWallpaper
动态壁纸实现
RenderScriptWallpaper

▲图18-5　各壁纸类的继承关系图

18.3.1 WallPaperManagerService

WPMS既然是基于AIDL实现的，我们来看看它的接口描述：

```
/*frameworks/base/core/java/android/app/IWallpaperManager.aidl*/
interface IWallpaperManager {
    ParcelFileDescriptor setWallpaper(String name); /*设置壁纸*/
    void setWallpaperComponent(in ComponentName name); /*设置动态壁
    ParcelFileDescriptor getWallpaper(IWallpaperManagerCallback c
    WallpaperInfo getWallpaperInfo();
    …
}
```

从上面的接口定义可以看出，WPMS的工作并不复杂——它提供了全局的壁纸注册、取消和查询功能，并在接收到事件时进行合理分配。

和其他系统服务一样，WPMS是在SystemServer.java中启动并注册进ServiceManager中的，如下所示：

```
/*frameworks/base/services/java/com/android/server/SystemSer
try {
       Slog.i(TAG, "Wallpaper Service");
       if (!headless) {
            wallpaper = new WallpaperManagerService(context)
            ServiceManager.addService(Context.WALLPAPER_SERV
       }
} catch (Throwable e) {
   reportWtf("starting Wallpaper Service", e);
}
```

接下来的一个问题是：既然系统同时支持静态壁纸和动态壁纸，而且每种类型中还包含了N个实例（比如原生态系统就自带多个动态壁纸供用户选择），那么系统在显示时是如何选择的呢？我们很自然地会想到，在WPMS启动时它应该会去读取某个“配置文件”，这个文件记录了用户最近一次的选择：

```
public WallpaperManagerService(Context context) {
    …
    loadSettingsLocked(UserHandle.USER_OWNER);//加载配置
}
```

当WPMS构造时，它调用了loadSettingsLocked:

```
private void loadSettingsLocked(int userId) {//这里传进来的user
    …
    try {
        stream = new FileInputStream(file);
        XmlPullParser parser = Xml.newPullParser();
        parser.setInput(stream, null);
        int type;
        do {
            type = parser.next();
            if (type == XmlPullParser.START_TAG) {
                String tag = parser.getName();
                if ("wp".equals(tag)) {…
                    wallpaper.name = parser.getAttributeValue
                    String comp = parser.getAttributeValue(nu
                    …
                }
            }
        } while (type != XmlPullParser.END_DOCUMENT);
        success = true;
    }
 …
}
```

上面这段代码会按照写入时的格式将wallpaper的配置信息读出来，并保存在WallpaperData结构中——专门用于描述壁纸信息的通用数据结构。不过这时壁纸还没有真正显示出来，而是要等到系统进入Ready状态（此时系统会回调SystemReady接口）后才会通知具体的壁纸程序进行绘制:

```
public void systemReady() {
    WallpaperData wallpaper = mWallpaperMap.get(UserHandle.US
    switchWallpaper(wallpaper, null);
    …
}
```

接着进入Wallpaper的具体处理中:

```
void switchWallpaper(WallpaperData wallpaper, IRemoteCallback
    synchronized (mLock) {…
        try {
            ComponentName cname = wallpaper.wallpaperComponen
                wallpaper.wallpaperComponent : wallpaper.next
            if (bindWallpaperComponentLocked(cname, true, fal
```

```
                return;
            }
        } …
}
```

系统开机后，wallpaper.wallpaperComponent为空（除非上一次用户选择了其他方式）；而wallpaper.nextWallpaperComponent则在loadSettingsLocked中被设置为wallpaper.imageWallpaper Component，即我们前面提到的ImageWallpaper这个Service。所以当调用bindWallpaperComponent Locked时，传入的cname就代表了ImageWallpaper。从bindWallpaperComponentLocked的函数名称可以看出，它将会以bindService的方式来启动目标壁纸Service（所以后期如果确认已经不再使用这个Service，还要主动执行unbind，然后这个壁纸服务就会自动销毁）。

WPMS启动后就可以接收客户端的请求了，因为它属于实名的BinderServer，意味着所有人都可以自由地使用它所提供的服务。比如我们既可以在系统自带的Launcher应用程序中选择壁纸，也完全可以自己编写一个更改壁纸的应用程序。

下面我们以设置壁纸这一场景为例来分析WPMS的内部实现：

```
 /*frameworks/base/services/java/com/android/server/Wallpaper
public ParcelFileDescriptor setWallpaper(String name) {
    checkPermission(android.Manifest.permission.SET_WALLPAPER
    synchronized (mLock) {
        int userId = UserHandle.getCallingUserId();
        WallpaperData wallpaper = mWallpaperMap.get(userId);
        …
        final long ident = Binder.clearCallingIdentity();
        try {
            ParcelFileDescriptor pfd = updateWallpaperBitmapL
            …
            return pfd;
        } finally {
            Binder.restoreCallingIdentity(ident);
        }
    }
}
```

首先系统会做下权限检查，所以提供壁纸设置功能的应用程序一定要在AndroidManifest.xml中显式写上如下权限声明：

```
<uses-permission android:name="android.permission.SET_WALLPAPER"
```

变量wallpaper是从mWallpaperMap取出来的，代表UserId为0时的壁纸——如果不为空就进入以下函数：

```
ParcelFileDescriptor updateWallpaperBitmapLocked(String name,
    if (name == null) name = "";
    try {
        File dir = getWallpaperDir(wallpaper.userId);//wallpa
        if (!dir.exists()) {//指定的路径不存在，需要创建
            dir.mkdir();
            FileUtils.setPermissions(dir.getPath(),
                    FileUtils.S_IRWXU|FileUtils.S_IRWXG|FileU
        }
        File file = new File(dir, WALLPAPER);
       ParcelFileDescriptor=ParcelFileDescriptor.open(file,
                                                     MODE_CREAT
        if (!SELinux.restorecon(file)) {
            return null;
        }
        wallpaper.name = name;
        return fd;
    } catch (FileNotFoundException e) {
        Slog.w(TAG, "Error setting wallpaper", e);
    }
    return null;
}
```

上面getWallpaperDir将得到一个WALLPAPER_BASE_DIR+"/"+userId的路径，其中WALLPAPER_BASE_DIR默认值是"/data/system/users"。

图18-6是userId为0时的情况。

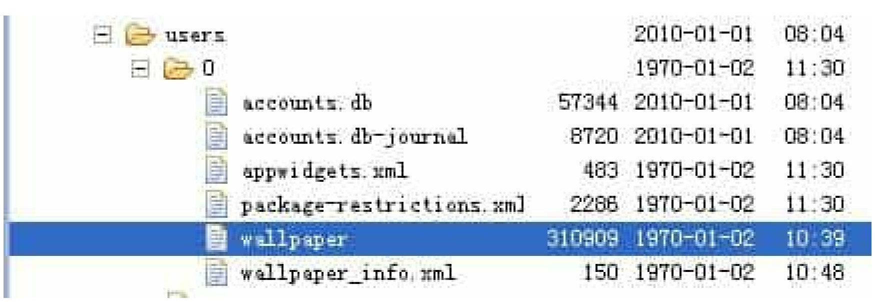

▲图18-6 UserId为0时的情况

假如这个目录不存在，要首先mkdir出来，然后在下面新建一个名

为WALLPAPER即“wallpaper”的文件，最后打开这个文件，并将描述符返回给调用者。

18.3.2　ImageWallpaper

前面讲过，当WPMS开机启动时，默认情况下会选择ImageWallpaper这个壁纸实现，并且以bindService的方式来启动它。在bindService中，WPMS同时传入名为newConn的Binder对象（WallpaperConnection）来使ImageWallpaper（其他WallpaperService也是一样的）可以访问到WPMS。而ImageWallpaper则响应onBind返回一个IWallpaperServiceWrapper的Binder对象，如图18-7所示。

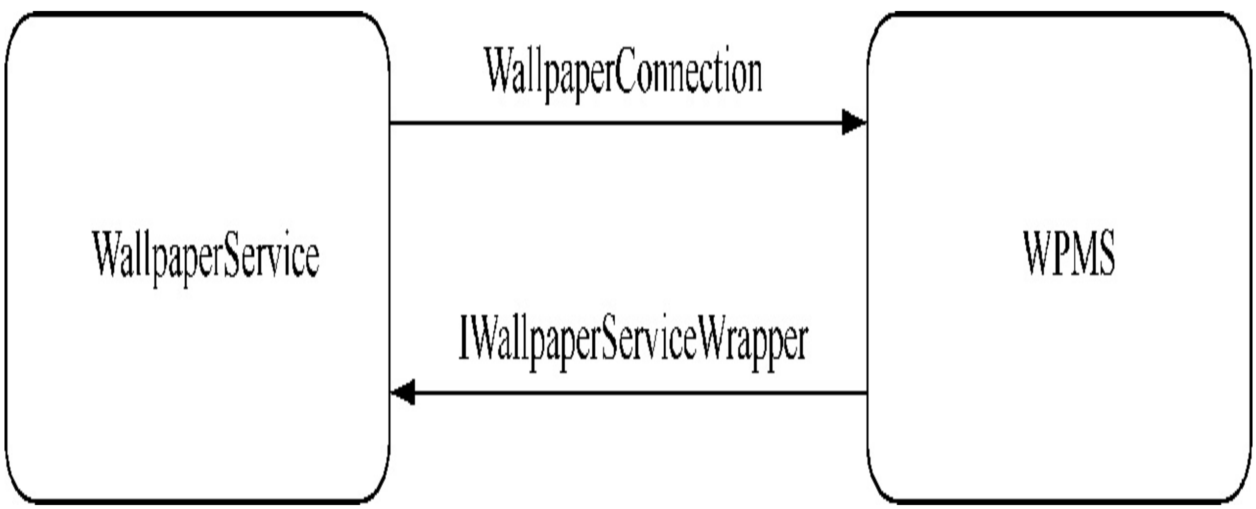

▲图18-7　WPMS与WPS间的IPC通信

我们来看看当绑定成功后WPMS中的操作：

```
public void onServiceConnected(ComponentName name, IBinder
     synchronized (mLock) {
         if (mWallpaper.connection == this) {…
             attachServiceLocked(this, mWallpaper);
             …
             saveSettingsLocked(mWallpaper);
         }
     }
 }
```

WPMS除了要保存当前所选的壁纸外，还要调用attachServiceLocked（间接调用Iwallpaper

ServiceWrapper.attach）来执行实际的工作。这部分逻辑比较简单，我们就不细化分析了。

WPS这边的attach函数将生成一个IWallpaperEngineWrapper对象并给它发送一个DO_ATTACH，这个消息最终由IWallpaperEngineWrapper.executeMessage来处理：

```
        public void executeMessage(Message message) {
            switch (message.what) {
                case DO_ATTACH: {
                    try {
                        mConnection.attachEngine(this);
                    } catch (RemoteException e) {
                        Log.w(TAG, "Wallpaper host disappeared",
                        return;
                    }
                    Engine engine = onCreateEngine();
                    mEngine = engine;
                    mActiveEngines.add(engine);
                    engine.attach(this);
                    return;
                }
```

上述代码段通过onCreateEngine生成了一个壁纸引擎——这也是各壁纸应用间最核心的差异。所以系统要求每一个WallpaperService实例必须要重载onCreateEngine来实现自己的engine。在ImageWallpaper中，它将产生一个DrawableEngine——这个engine随后会被加入mActiveEngines的全局list中，然后调用它提供的attach接口。如下所示：

```
     /*frameworks/base/core/java/android/service/wallpaper/Wallpa
     public class Engine {…
          void attach(IWallpaperEngineWrapper wrapper) {…
            mSession = WindowManagerGlobal.getWindowSession();
            mWindow.setSession(mSession);
            …
            IntentFilter filter = new IntentFilter();
            filter.addAction(Intent.ACTION_SCREEN_ON);
            filter.addAction(Intent.ACTION_SCREEN_OFF);
            registerReceiver(mReceiver, filter);
            …
            updateSurface(false, false, false);//更新Surface
}…
```

Engine内部首先需要进行各重要变量的初始化，然后注册监听屏幕的开/关事件，最后调用updateSurface。

我们知道，WallpaperService作为一个壁纸服务的基类，它的工作就是为具体的壁纸类创建“共有的属性”。比如所有的壁纸应用都需要Surface来输出图像，并针对系统中产生的实时事件做出正确处理。WallpaperService一方面会为这些事件的处理提供统一的解决方案，另一方面需要考虑各engine子类的特性。换句话说，一个扩展的engine类可以有选择地实现如下方法。

- onCreate

只会调用一次，用于初始化engine。该方法返回后程序就开始创建这个壁纸实例的Surface。

- onDestroy

一个engine即将被销毁前会调用。该方法返回后上述创建的Surface就会被destroyed，因此engine也就无效了。

- onVisibilityChanged

通知该壁纸当前是可见或者隐藏状态。WallpaperService要求壁纸实例只有在visible时才能占用CPU资源，这点要特别注意。

- onTouchEvent

用户触发了触摸屏事件。

- onCommand

接收到WallpaperManager发过来的command。

- onSurfaceChanged

Surface发生改变。

- onSurfaceRedrawNeeded

需要重绘Surface。

- onSurfaceCreated

  Surface创建成功。

- onSurfaceDestroyed

  Surface被销毁。

注意

后面几个关于Surface的方法和SurfaceHolder.Callback类是一致的。

了解了这些接口后，我们回头看updateSurface就清楚多了。这个函数会根据当前的具体情况来回调壁纸实例提供的engine相应接口，以实现壁纸的各种功能。函数首先判断forceRelayout || creating || surfaceCreating || formatChanged || sizeChanged || typeChanged || flagsChanged || redrawNeeded等条件是否有变动——是的话内部再进行细化处理，否则直接返回。

如果mCreated为空，说明还没有在WMS中做过注册。此时需要通过mSession.addToDisplay来执行注册操作。如果Surface还没有创建，也需要先生成一个可用的Surface——这些操作流程和我们在显示系统中的分析完全一致，读者可以回头参考下。

经过updateSurface取得有效的Surface和UI绘制环境后，ImageWallpaper就能进一步将“壁纸界面”经由SurfaceFlinger显示到终端屏幕上了。这部分内容比较简单，读者可以作为练习自行阅读分析。

第19章 Android常用的工具“小插件”——Widget机制

Widget俗称“小插件”，是Android系统中一个很常用的工具。比如我们可以在Launcher中添加一个音乐播放器的Widget，以快速控制歌曲的下一曲/上一曲、音量等；也可以使用“天气”或者“时钟”小插件来获得当地的气温和时间信息。Widget给Android系统带来了更便捷的用户体验，因此受到广泛的欢迎，如图19-1所示。

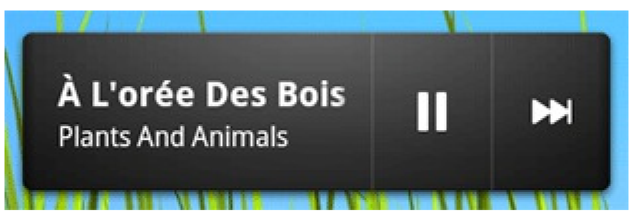

▲图19-1　一个音乐播放器Widget示例

大家都知道，在Launcher上可以添加插件，那么是不是说只有Launcher才具备这个功能呢？我们可以换个角度来思考一下，Launcher本质上只是一个APK应用程序，所以它能做到的事情理论上在其他任何应用程序中也都能做到。

所以可以很肯定地说：不是。Android系统并没有具体规定谁才能充当“Widget容器”这个角色。它定义了一套完整的Widget添加/移除和显示机制，使得人人都能当“Widget提供者”，人人也都有资格做“Widget容器”。Widget虽然名为小插件，它的实现原理却是“内有乾坤”，比普通的应用程序要稍微难一些。本章将为读者全面剖析Android系统中的Widget体系——相信读者在深入了解了其内部原理

后，再来开发Widget应用就会容易得多。

上面我们提到了“Widget提供者”和“Widget容器”这样的概念，前者如一个天气插件，后者则如Launcher。在Widget机制中，它们都有各自的专有名词（同时也是类名），分别是AppWidgetProvider和AppWidgetHost。除此之外，我们能猜想到系统中还需要一个全局的Widget管理器。类似于WindowManagerService、WallpaperManagerService的命名方式，它叫作AppWidgetService。在接下来的小节中我们将逐个介绍它们，如图19-2所示。

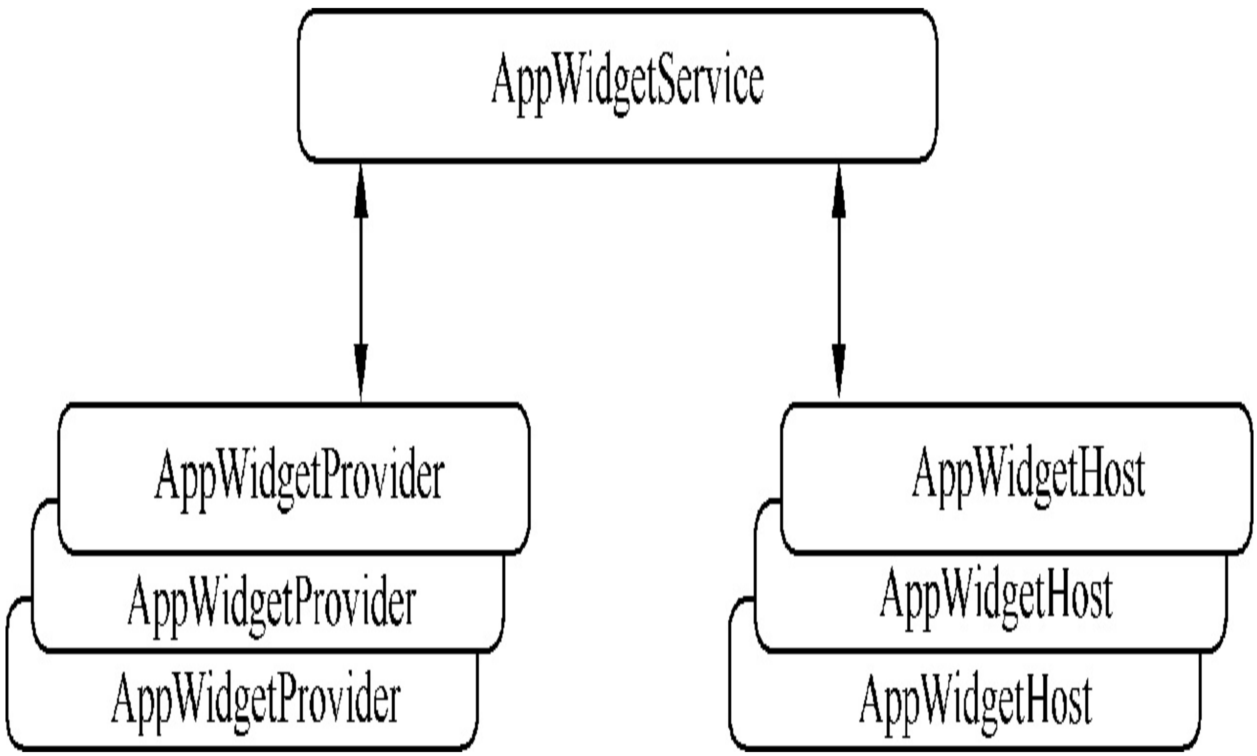

▲图19-2　Widget架构中的重要组成元素

19.1 “功能的提供者”——AppWidgetProvider

对于大部分开发人员来说，AppWidgetProvider是他们最熟悉的。既然叫作Provider，言下之意就是“功能的提供者”。从Host的角度来说，它没有办法预先知晓用户会添加多少个Widget，也没有办法知晓这些添加的Widget都实现了哪些功能。所以在Host的“世界”里，一个Widget只是一个View——它只需要按照要求进行正确显示即可，具体的功能实现则由AppWidgetProvider来完成。

希望读者可以谨记并在后续分析中验证这个结论：

Host把Widget看成View的一个“变种”。

一个有效的Provider要提供至少以下几方面的内容。

- AppWidgetProviderInfo

也就是用于描述这个Widget的各种信息，包括它的layout布局、刷新频率以及下面要提到的AppWidgetProvider等。这些信息以XML格式的文件表示，Tag标志为<appwidget-provider>。

- AppWidgetProvider

既然Widget最终是要被显示在Host中的，那么它的功能实现和普通应用程序就一定会有差异。AppWidgetProvider主要借助于Broadcast事件来对Widget进行“远程更新”，后面我们会详细分析。

- View布局

AppWidgetProviderInfo用于描述这个Widget的整体信息，而这里的Layout则是专门用于描述Widget的“显示部分”（确切地说，是初始化时的显示）。

基于上面的分析，不难推测出Provider就是一个BroadcastReceiver。比如我们可以在AndroidManifest.xml中声明以下内容来定义一个AppWidgetProvider：

```
<receiver android:name="ExampleAppWidgetProvider" >
```

```
 <intent-filter>
  <action android:name="android.appwidget.action.APPWIDGET_UPDATE
 </intent-filter>
 <meta-data android:name="android.appwidget.provider"
            android:resource="@xml/example_appwidget_info" />
</receiver>
```

这个receiver要接收的唯一消息，就是APPWIDGET_UPDATE；并且它还需要带有<meta-data>信息明确指明自己是一个"android.appwidget.provider"，最后的android:resource即前面说到的AppWidgetProviderInfo。比如：

```
<appwidget-provider xmlns:android="http://schemas.android.com/apk
    android:minWidth="294dp"
    android:minHeight="72dp"
    android:updatePeriodMillis="86400000"
    android:previewImage="@drawable/preview"
    android:initialLayout="@layout/example_appwidget"
</appwidget-provider>
```

这个XML文件的最后一项属性（android:initialLayout）指定了初始的View布局为example_ appwidget，它和我们编写普通应用程序的布局语法一样。不过要特别注意的是：

Widget中的Layout布局是基于RemoteViews的，因而并不是所有的View组件都可以使用，具体细节可以参考官方文档的说明。

当我们编写一个自己的Widget Provider时，首先要继承自AppWidgetProvider。后者的内部实现并不复杂，它继承自BroadcastReceiver，并在onReceive中将具体事件通过重载函数通知我们的AppWidgetProvider实例：

```
/*frameworks/base/core/java/android/appwidget/AppWidgetProvider.j
public class AppWidgetProvider extends BroadcastReceiver {
     …
    public void onReceive(Context context, Intent intent) {
        String action = intent.getAction();
        if (AppWidgetManager.ACTION_APPWIDGET_UPDATE.equals(actio
           Bundle extras = intent.getExtras();
           if (extras != null) {
              int[] appWidgetIds = extras.getIntArray(AppWidgetMa
              if (appWidgetIds != null && appWidgetIds.length > 0
                  this.onUpdate(context, AppWidgetManager.getInst
```

```
                }
            }
        }
    …
    }…
```

可以看到当action为ACTION_APPWIDGET_UPDATE，具体的处理者是onUpdate。而其他情况下分别是：

ACTION_APPWIDGET_DELETED→onDeleted

ACTION_APPWIDGET_OPTIONS_CHANGED→onAppWidgetOptionsChanged

ACTION_APPWIDGET_ENABLED→onEnabled

ACTION_APPWIDGET_DISABLED→onDisabled

也就是说，编写一个Widget应该根据需求来重载onReceiver（如果有需要的话），onUpdate，onAppWidgetOptionsChanged，onDeleted，onEnabled以及onDisabled。它们分别会在此Widget被更新、Option改变、被删除等情况下被调用。

- onUpdate

如果在AppWidgetProviderInfo中定义了updatePeriodMillis，系统就会根据这个时间间隔来周期性地产生ACTION_APPWIDGET_UPDATE。另外，当用户添加了Widget时也会产生这一事件。

- onAppWidgetOptionsChanged

这个方法主要用于处理Widget的尺寸变化，因而可以猜到在第一次添加时也会被调用。以后当用户改变Widget的大小后才会产生这一事件。

- 其他

其他几个方法比较好理解，我们就不一一介绍了。不过要特别注意的是，一个Widget是可以有多个具体实例的。比如我们写了一个“天气”插件供用户使用，那么理论上并不限制用户会在Launcher中添加多

少个“天气”实例。因而需要有相应的WidgetId来唯一标识每一个实例，如图19-3所示。

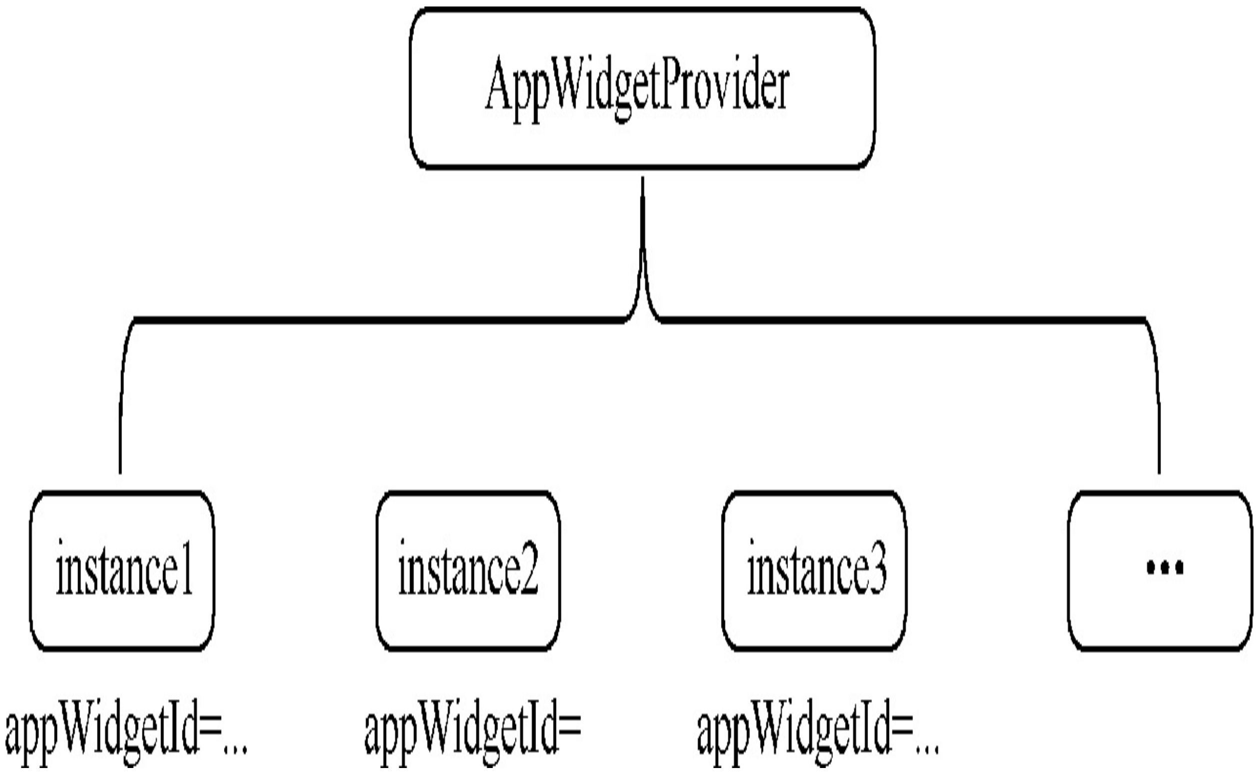

▲图19-3　AppWidgetProvider可以有多个实例

19.2 AppWidgetHost

上一小节我们了解了AppWidgetProvider所要做的工作，接下来再看看Host又是如何配合Provider的。简而言之，Host这个“东道主”需要提供相应的空间供Widget来展现自己的UI界面。打个比方，AppWidgetHost就好比一个展厅，而至于陈列的汽车是大众还是奔驰品牌都是没问题的——取决于Widget本身的意愿。

成为一个AppWidgetHost，它需要解决以下问题。

- 如何显示Widget的UI界面

也就是说，展厅本身需要为每一个参展的Widget做好规划，如展出的时间、具体的展出位置、占地大小、以什么样的方式展出等。

- 如何与AppWidgetProvider通信

某个客户看中了展厅上摆放的某辆参展车，那么作为Host就要及时通知参展商这一事件。受Widget特性的限制，我们在普通应用程序中能实现的事件在Widget机制中未必可以正常工作。比如APK应用程序中的View组件响应左右滑动这一Gesture是很简单的事——但是“寄居”于Launcher中的Widget就需要特别注意，因为左右滑动这个手势在Launcher中代表了翻页。换句话说，Widget将得不到左右滑动的事件。即便开发人员可以通过修改Launcher源码来达到相同的效果，这种方法对于后期添加的Widget显然也是无能为力的。

前一小节我们分析过，一个AppWidgetProvider与外界的接口就是onReceive，然后再细化为onUpdate，onEnable等事件处理。而产生这些事件的根源，除了AppWidgetService这一系统元素外，就是AppWidgetHost了。只不过后者也是要通过前者来发送事件的，如图19-4所示。

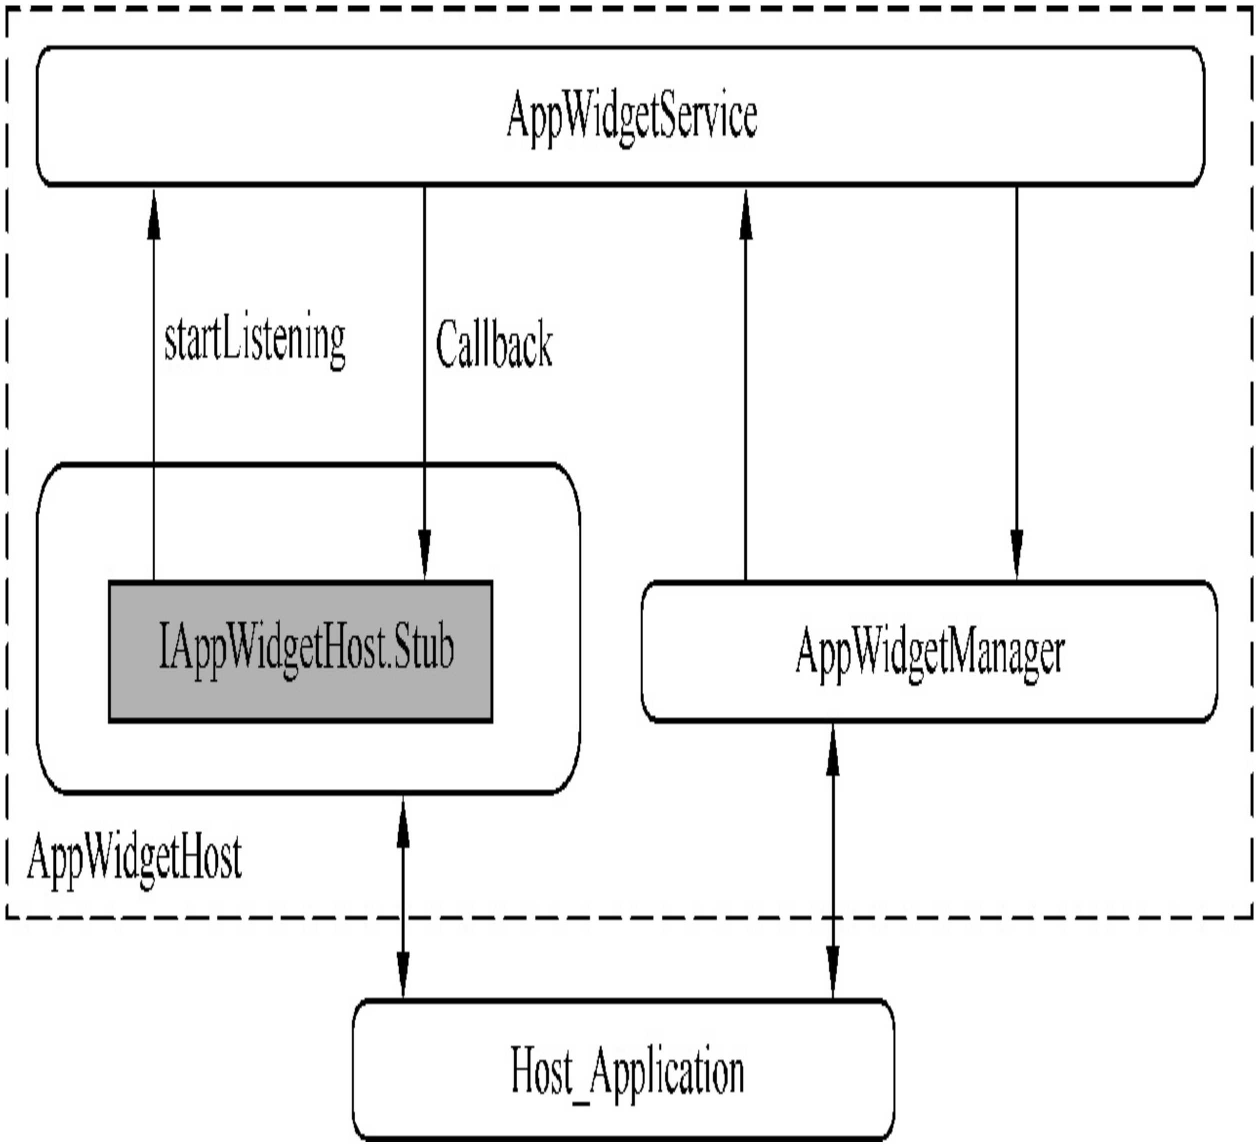

▲图19-4　AppWidgetHost与Widget系统间的接口

简图中的Host_Application是指扮演Host角色的应用程序，如Launcher。它在整个Widget机制中只会与AppWidgetManager进行交互而不会直接调用AppWidgetService的接口（这有点类似于ServiceManager.java的作用）。可想而知，AppWidgetManager内部还是要通过间接调用AppWidgetService来实现的。另外每个Host_Application还要持有一个AppWidgetHost，我们可以认为它是Host的代理。

当一个Host_Application创建后，它需要向AppWidgetService注册监听Widget事件，并提供一个callback实现。这个callback实际上继承

自IAppWidgetHost.Stub，即一个基于AIDL的BinderServer，这就保证了AppWidgetService在事件发生时可以回调到Host。需要接收的回调事件包括：

- updateAppWidget updateAppWidgetView@AppWidgetHost
- providerChangedonProviderChanged@AppWidgetHost
- viewDataChangedviewDataChanged @AppWidgetHost

我们以updateAppWidget为例来分析其内部实现：

```
 /*frameworks/base/core/java/android/appwidget/AppWidgetHost.
void updateAppWidgetView(int appWidgetId, RemoteViews views,
    AppWidgetHostView v;
    synchronized (mViews) {
        v = mViews.get(appWidgetId);
    }
    if (v != null) {
        v.updateAppWidget(views);
    }
}
```

当WidgetProvider希望更新Host中的View显示时（比如天气插件更新气温），它会通过AppWidgetManager.updateAppWidget（int appWidgetId, RemoteViews views）来指定新的View样式（RemoteViews）。这个请求最终由AppWidgetService发送给相应的Host来实现，即updateApp WidgetView。上面代码中的mViews定义如下：

```
HashMap<Integer,AppWidgetHostView> mViews = new HashMap<Integer,
                                                       AppWidgetH
```

它是一个AppWidgetHostView的集合。换句话说，是当前这个Host所包含的所有Widget的View对象。比如在Launcher中用户每添加一个Widget（或者设备刚开机时Launcher自己从保存的配置中读取需要加载显示的Widgets），就会用AppWidgetHost.createView把它加入这个集合中。另外因为Widget数量众多，必须为它们分配一个全局唯一的WidgetId。

1．Launcher中添加widget的操作过程

在Launcher中添加一个Widget，操作流程是：

首先，在主界面屏幕的空白处长按会弹出对话框，供用户选择需要添加到屏幕上的item类型，如图19-5所示。

当选择了“Widgets”后，程序通过带有Intent.action为AppWidgetManager.ACTION_ APPWIDGET_PICK的StartActivityForResult来启动系统的如图19-6所示界面。

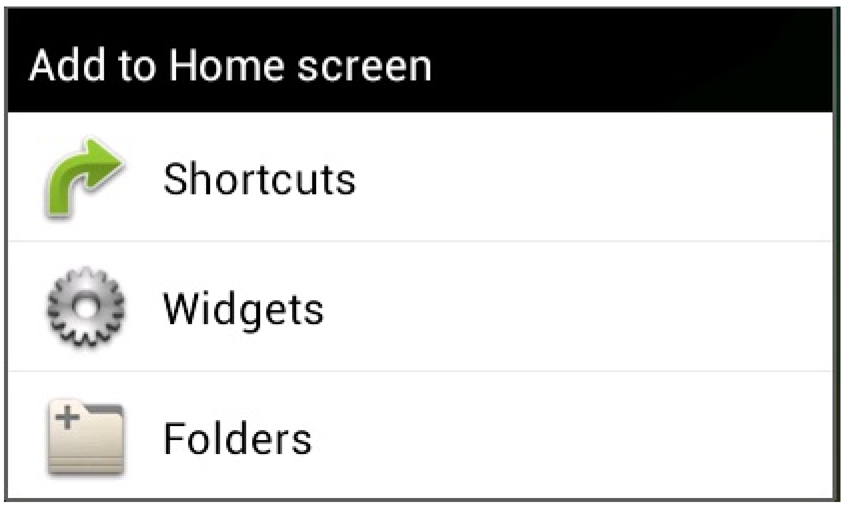

▲图19-5　空白处长按会弹出对话框

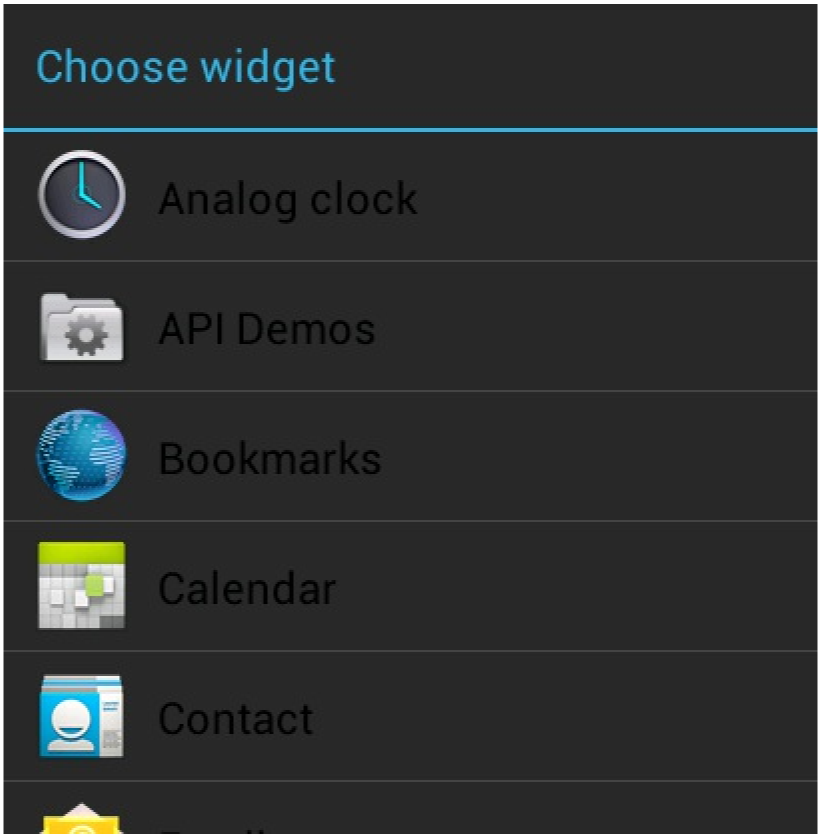

▲图19-6　界面

用户对widget的选择结果将通过Activity.onActivityResult返回给Host_Application。后者在做了相应处理后，还要发起第二次StartActivityForResult，这次的Intent.action为AppWidgetManager.ACTION_APPWIDGET_CONFIGURE——意在对该Widget进行初始化（configuration）。比如天气插件需要指定用户所在城市、设置更新频率等。如果该插件对应的AppWidgetProvider提供了ConfigurationActivity，此时就会被调用。

当配置结束后，通常Host_Application还会询问用户希望给Widget分配多大的显示空间，如2行2列或者2行3列等。做好这些准备后，Host_Application才能真正把这个Widget添加到自己的显示界面中。

2．widget在host中的显示流程

首先Host通过AppWidgetManager.getAppWidgetInfo来得到相应WidgetId的Info信息，即我们前一小节中讲到的AppWidgetProviderInfo。接着Host会通过AppWidgetHost.createView

产生一个AppWidgetHostView——这个View对应的布局是由前面的initialLayout指定的。后续AppWidget Provider根据实际情况还会通过RemoteViews来实时更新它的Widget显示。

那么，createView都做了哪些工作呢？

```
 /*frameworks/base/core/java/android/appwidget/AppWidgetHost.
public final AppWidgetHostView createView(Context context, in
                               AppWidgetProviderInfo appWidge
    final int userId = mContext.getUserId();
    AppWidgetHostView view = onCreateView(mContext, appWidget
    //本地的View对象
    view.setUserId(userId);
    view.setOnClickHandler(mOnClickHandler);
    view.setAppWidget(appWidgetId, appWidget);
    synchronized (mViews) {
        mViews.put(appWidgetId, view);
    }
    RemoteViews views;
    try {
        views = sService.getAppWidgetViews(appWidgetId, userI
        if (views != null) {
            views.setUser(new UserHandle(mContext.getUserId()
        }
    } catch (RemoteException e) {
        throw new RuntimeException("system server dead?", e);
    }
    view.updateAppWidget(views);//通过RemoteViews“搭建”本地的Vi
    return view;
}
```

第一步是要产生一个AppWidgetHostView，默认情况下onCreateView内部只是new了一个AppWidgetHostView对象然后就直接返回。如果读者有特殊需求，可以重载这个函数：

```
/*frameworks/base/core/java/android/appwidget/AppWidgetHostView.j
public class AppWidgetHostView extends FrameLayout {
…
```

可见，AppWidgetHostView实际上是FrameLayout的扩展子类。而setAppWidget一方面将widgetId与此AppWidgetHostView联系起来，另一方面设置了将要显示的widget的padding值，我们同样可以重载这一实现。

接下来就是widget显示的重点，即我们如何把Widget Provider定义的界面显示到Host_ Application中。

在分析源码前，我们先来打个比方。张三在北京建了一栋别墅，李四看了后很喜欢，于是也想自己在上海建一栋一模一样的。怎么办？显然不可能将张三的别墅直接挪到上海，因为它们是异地的，属于两个不同的“进程空间”。一个可行的办法就是将张三的建筑图纸完完本本地递交给李四，然后李四就可以在他自己的“进程空间”中兴建一栋一模一样的别墅了。虽然砖瓦、水泥可能用的不是一个品牌，但这丝毫不会影响大家认为“这两栋别墅的样式风格是完全一样的”。

Widget的显示也类似。我们需要在另一个进程空间（即Host_Application）中显示自己的View，那么也完全可以把View的“图纸”交给对方——这样对方只要“依葫芦画瓢”，也就不难“还原”出Widget的“真实面目”了。而这张“图纸”，就是RemoteViews：

```
/*RemoteViews.java*/
public class RemoteViews implements Parcelable, Filter {…
```

虽然它的名称中也带有“Views”，但实际上没有任何View的影子。它继承自可以跨进程传递的Parcelable类以及对数据进行约束的Filter类。

有了这些基础，我们再回头接着看前面的createView：

```
views = sService.getAppWidgetViews(appWidgetId);
```

上面这句代码根据WidgetId来得到一个RemoteViews，它借助于sService即AppWidgetService提供的接口来实现。实际上它只是简单填写了Widget的LayoutId和PackageName等，后面真正构造Widget的UI界面时才会去取“图纸”。

最后调用的updateAppWidget是真正构建widget界面的地方（分段阅读）：

```
    public void updateAppWidget(RemoteViews remoteViews) {…
        boolean recycled = false;
        View content = null;
        Exception exception = null;
        …
```

```
        if (remoteViews == null) {…
        } else {
            mRemoteContext = getRemoteContext(remoteViews);
            int layoutId = remoteViews.getLayoutId();/*Step1. 描述
            …
            if (content == null) {
                try {
                   content = remoteViews.apply(mContext, this, mO
                    创建Widget的View*/
                } catch (RuntimeException e) {
                    exception = e;
                }
            }
            mLayoutId = layoutId;
            mViewMode = VIEW_MODE_CONTENT;
        }
        …
        if (!recycled) {
            prepareView(content);
           addView(content);/*添加Widget的View到全局管理中*/
        }
        …
    }
```

Step1@ updateAppWidget。得到Widget所属的Context以及layoutId。做过主题换肤功能的开发者应该会觉得和这里所采用的思想基本一致。

Step2@ updateAppWidget。正常情况下程序需要调用RemoteViews.apply，其返回值content是一个View对象。一个合理的猜测即它应该就是根据Widget的“图纸”所创建出来的View，后面再详细分析这个函数。

Step3@ updateAppWidget。前面我们说过AppWidgetHostView是一个FrameLayout，因而作为ViewGroup它可以通过addView来添加子View（即content变量）。

小结一下这个函数，简单来讲它做了两件事。

- 生成一个View（content变量）

这个View根据推测就是由Widget的“图纸”生成的，因而代表了Widget的UI界面。

- 将上述View加到AppWidgetHostView中

AppWidgetHostView是一个FrameLayout，它将content作为子View添加进来。这样当整个View重绘时，Widget的界面自然也就呈现出来了。

来看看上面代码段中apply函数的实现：

```
 /*frameworks/base/core/java/android/widget/RemoteViews.java*
public View apply(Context context, ViewGroup parent, OnClickH
    RemoteViews rvToApply = getRemoteViewsToApply(context);
    View result;
    Context c = prepareContext(context);
    LayoutInflater inflater = (LayoutInflater)c.
                               getSystemService(Context.LAYOU
    …
    result=inflater.inflate(rvToApply.getLayoutId(), parent,
    …
    return result;
}
```

读者可以先思考下：如果已知一个xml描述的layout布局，要怎么才能把它变成代码中的ViewTree呢？答案就是通过层层解析这个xml文件，然后按照递归顺序来逐步生成文件中描述的每个View对象，并把它们有机地组织起来（树的形式）。

明白这些道理后，apply函数就容易理解了。它就是通过inflater来完成工作的。具体的实现过程我们就不深究了，有兴趣的读者可以自行分析。

这样程序就按照Widget提供的“图纸”成功地在host进程中构造出本地的View对象了——它会和Host_Application中其他View一起，经过SurfaceFlinger的处理后最终显示到屏幕上。

Widget机制的设计很有技巧，希望读者可以再深入“品味”。

第20章
Android应用程序的编译和打包

Android系统的APK应用程序可以有如下几种编译方式。

- 借助系统编译

本书曾对Android系统的编译框架进行过完整分析。它利用Android.mk文件将众多小项目组织起来，并且提供了非常方便的函数以编译出各种可执行文件、库和应用程序等。理论上应用开发人员可以将APK源码添加到整个Android工程中，然后借助于系统编译来间接完成应用程序的编译——只不过这种方式并不多见。一方面，这要求开发工程师对整个系统的编译框架有一定的认识；另一方面，这意味着开发应用程序还需要下载整个Android工程，而且每次编译的时间也会很长。

- 借助于IDE工具

所以一般情况下，APK应用程序（非系统级应用）的开发都会借助于IDE工具——比如适配于Eclipse的ADT就是使用最广泛的一种。Android提供的ADT组件不仅可以用于快速建立应用程序的原型，其集成的各种辅助功能也可帮助开发人员便捷地编写、编译和调试应用程序。

- 命令行编译

工程师在ADT的帮助下，可以“不费吹灰之力”地完成编译。但是这种“傻瓜式”的操作方式造成的一个副作用，就是很多人对应用程序的编译、打包、签名等基础过程都“一知半解”。

本章我们将向读者系统地讲解隐藏在“ADT”背后的这些细节。

20.1 “另辟蹊径”采用第三方工具——Ant

软件编译需要用到哪些工具呢？

编译器是毋庸置疑的，如GCC——而且理论上这就足够了。但随着软件工程的发展，很多项目的源码数量不断膨胀，因而单纯地使用GCC已经无法满足要求了。举一个例子，Android工程有成千上万个文件，开发人员不可能手工逐个执行GCC命令。所以必须有其他工具来管理这些零碎的文件，并有目的地把它们组织成最终的系统image——这就是make的意义所在。

那么我们编译一个APK，是不是也要用到make？

理论上当然可以这样做，但Google没有选择这种方式，而是“另辟蹊径”采用了第三方工具——Ant。

Ant是“Another Neat Tool”的缩写，由Apache开发。从“Another”可以看出一点端倪，Ant很可能是以某个经典工具为原型改进而来的，并且相对于原有工具更加“Neat”——事实也的确如此。Ant的开发者原先供职于Sun公司，他在开发著名的JSP/Servlet（即后来的Tomcat）时，发现传统的make方法太依赖于操作系统环境，由此对研发人员的工作造成了不少的影响。

因此Ant被设计采用Java语言来开发，并且以XML文件（默认为build.xml）来描述编译过程和依赖关系。这相对于Makefile来说更为简洁易懂，也更富有扩展性，所以在Java工程中逐渐得到了广泛的应用。

下面我们介绍Ant的几个常见命令。其他命令的用法也类似，有兴趣的读者请自行参阅它的官方网站：http://ant.apache.org。

```
ant release
```

编译一个release版本的项目。

```
ant debug
```

编译一个debug版本的项目。

ant installd

安装一个已经compiled过的debug包。

ant installr

安装一个已经compiled过的release包。

ant installt

安装一个已经compiled过的测试包，同时安装被测试应用的.apk文件。

ant <build_target> install

编译并安装一个程序包。

ant clean

清理一个项目，或者如果使用了ant all clean，则所有相关项目都会被清理。

特别提醒，如果你是在Windows操作系统环境下开发Apk应用程序，那么要注意JDK的安装路径。因为默认情况下，JDK安装在“Program Files”目录中，而这中间的空格将导致Ant无法正常运行。解决的办法有两个：

- set JAVA_HOME= "c:\Progra～1\Java\<jdkdir> ";
- 或者将JDK安装到名称不带空格的路径中。

20.2 通过命令行编译和打包APK

简单来说，Ant可以提供两种编译方式，即debug和release；而且不论何种方式生成的应用程序，都需要经过签名和zipalign的优化——只不过debug版本默认就会帮助开发者自动完成这些工作。关于签名过程的详细描述，请参阅下一小节。

Debug模式

编译debug版本的项目，步骤如下。

- 命令行模式下，进入你的工程目录。
- 使用ant debug命令进行编译。

这样就会在项目的bin目录下生成一个后缀为“-debug.apk”的文件，而且它已经用debug key签过名，也经过了zipalign的优化。

Release模式

虽然上面的debug模式非常方便，但并不适用于正式发布的应用程序。其中一个重要原因就是它采用的是系统默认的签名文件，没有起到很好的安全保护作用。

在release模式下，签名和zipalign优化都需要开发者手工完成。一般步骤如下：

- 命令行模式下，进入你的工程目录；
- 使用ant release命令进行编译；
- 在bin目录下会生成以“-unsigned.apk”为后缀的APK文件；
- 利用Jarsigner或者其他类似工具为apk签名（用私钥签名）；
- 利用zipalign优化应用程序。

可能有读者认为这个过程比较烦琐，这里有一个简化的方法可以在release模式下自动为APK签名和优化。

- 找到项目根目录下的ant.properties文件。
- 加入如下两条信息：

```
key.store=path/to/my.keystore
key.alias=mykeystore
```

这样ant release命令在生成APK的过程中会主动要求用户输入密码，而编译完成后的应用程序就已经用你提供的my.keystore签过名了。

编译生成的APK还需要安装到模拟器或设备上以供用户使用。在Eclipse上，我们只要点击“Run->Run/Debug”就可以将程序安装到目标上（目标可以是模拟器或设备。具体选择哪个一方面取决于当前设备的连接情况，另一方面与Run/Debug Configurations里Target页中的设

置有关）。实际上这一过程借助了adb的install功能，因而命令行模式下，我们也同样可以使用adb install来达到相同的目的。关于adb install的更多描述，可以参见本书工具篇对adb的专门讲解，这里不再赘述。

20.3 APK编译过程详解

前面我们对Ant的两种编译模式进行了概述，并从使用者的角度向读者介绍了命令行模式下的编译方法。接下来我们将进一步解析编译过程的每一个环节，即Android是如何将项目源码编译、打包成最终的.apk文件的。

以APK为后缀的文件是Android应用程序的标准格式。它其实是一个zip压缩包，所以可用WinRar等工具将其解压出来。可以看到，一个典型的APK应用程序包含了以下几部分内容：

```
|-- AndroidManifest.xml
|-- classes.dex
|-- resources.arsc
|-- res
|    |-- drawable
|    |    `-- icon.png
|    |-- layout
|     |    `-- main.xml
|   |-- xml
|-- META-INF
|    |-- CERT.RSA
|    |-- CERT.SF]
|    |-- MANIFEST.MF
```

- AndroidManifest.xml

这个文件相信读者都不会陌生。如果应用程序是一本书，那么这个文件就是它的“封面”和“目录”，记载了应用程序的名称、权限声明、所包含的组件等一系列信息。不过直接从APK解压出来的AndroidManfiest是无法打开的，因为发布时它已经被做了加密保护处理。

- classes.dex

APK应用程序的核心。它是由项目源码生成的.class文件，经进一步转化而成Android系统可识别的Dalvik Byte Code。如果APK引用了第三方jar包的话，那么通常情况下它也会被包含在classes.dex中（因为Android系统中的字节码和标准JVM中的字节码是有区别的，参考本书的

Android虚拟机章节）。

- resources.arsc

  编译过后的资源文件。

- res目录

  未编译的资源文件。

- META-INF目录

用于保存应用程序的签名和校验信息，以保证程序的完整性。生成APK包时，系统会对包中的所有内容做一次校验，然后将结果保存在这里。而设备在安装这一应用程序时还会对内容再做一次校验，并和META-INF中的值进行比较，以避免程序包被恶意篡改。

图20-1详细描述了整个编译过程。

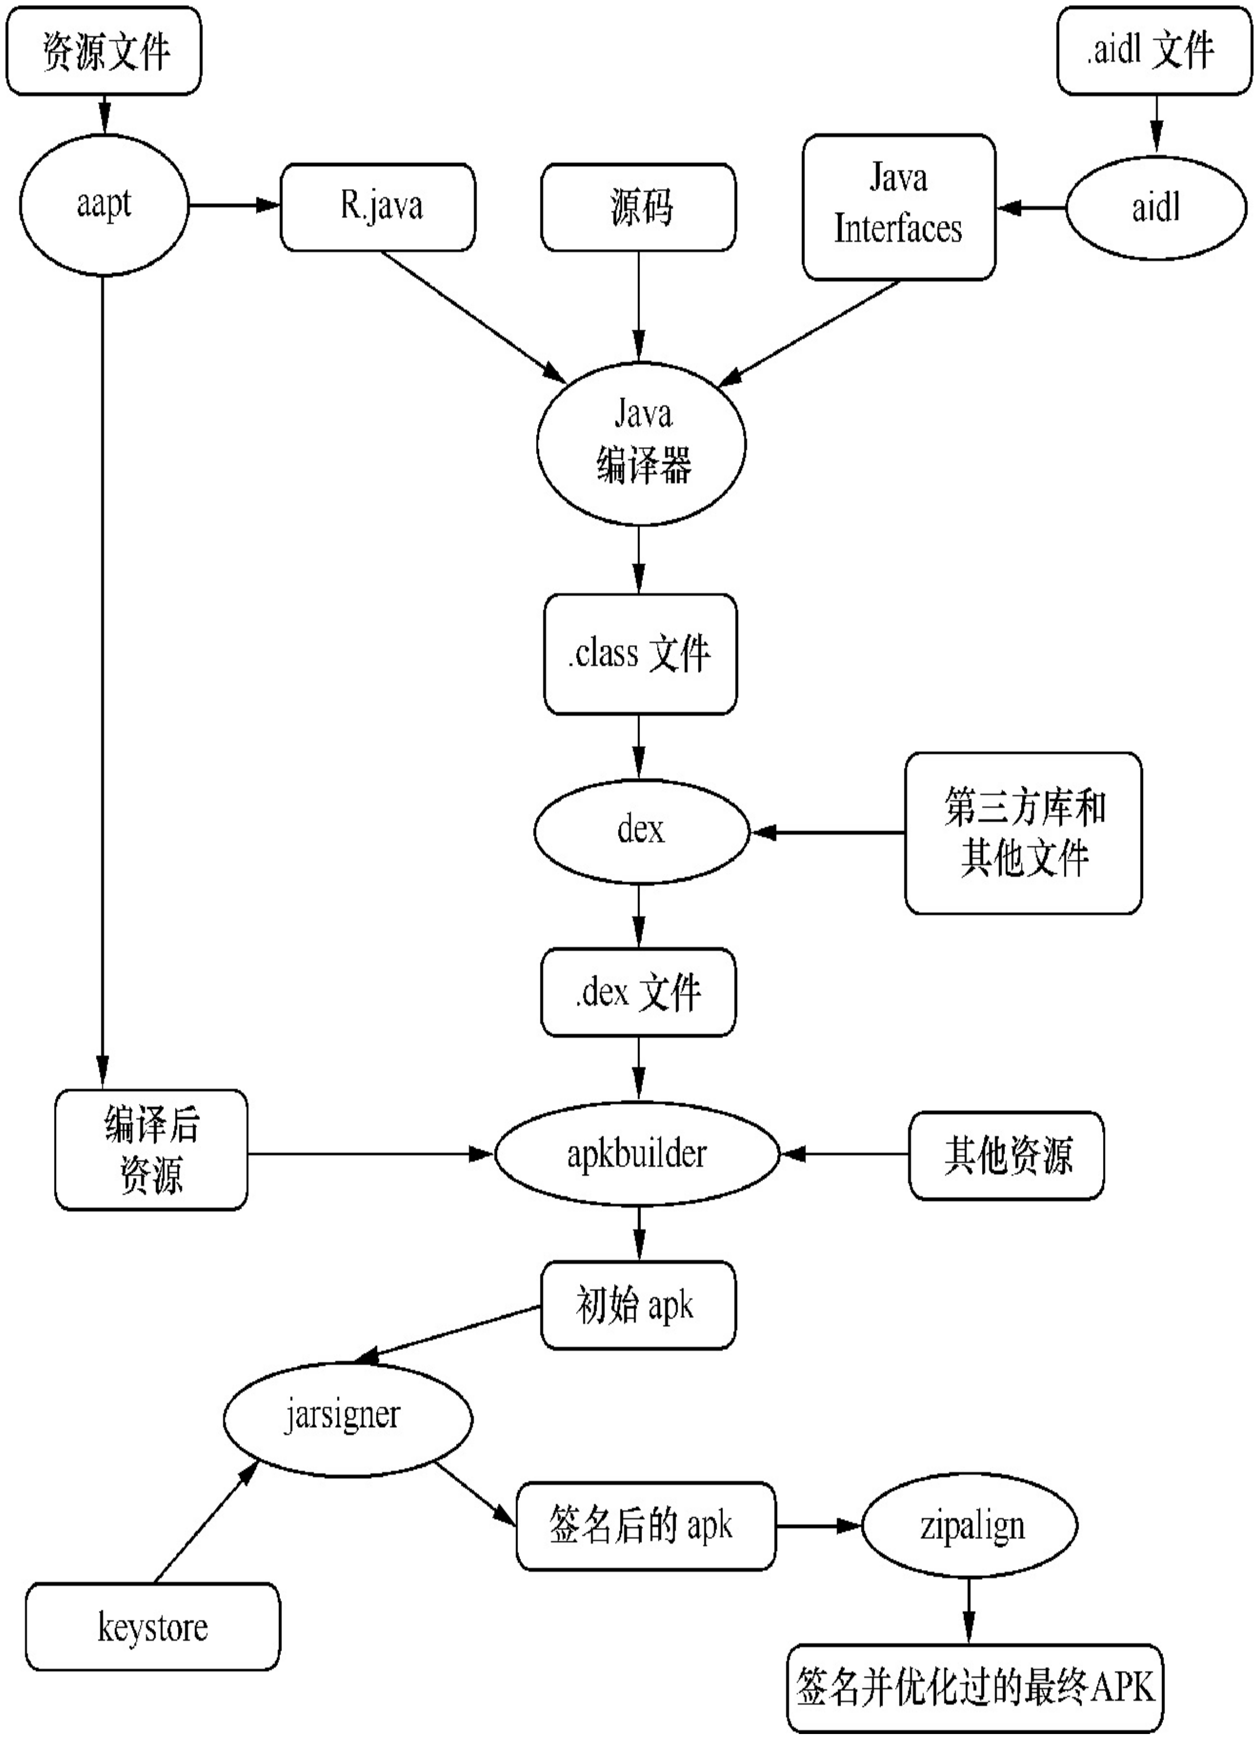

资源文件
.aidl 文件
aapt
R.java
源码
Java Interfaces
aidl
Java 编译器
.class 文件
dex
第三方库和其他文件
.dex 文件
编译后资源
apkbuilder
其他资源
初始 apk
jarsigner
签名后的 apk
zipalign
keystore
签名并优化过的最终APK

▲图20-1　APK编译全过程图解

可以清楚地看到，整个编译过程涉及了多种工具。下面对其中的几个重要步骤进行讲解。

- 首先.aidl（Android Interface Description Language）文件需要通过aidl工具转换成编译器能处理的Java接口文件。
- 同时资源文件将被aapt（Asset Packaging Tool）处理为最终的resources.arsc，并生成R.java文件以保证源码编写时可以方便地访问到这些资源。
- Java的编译器将R.java，Java源码文件以及上述生成的接口文件统一编译成.class文件。
- 因为.class并不是Android系统所能识别的格式，所以还要利用dex工具将它们转化为Dalvik字节码。这个过程中还会加入程序依赖的所有“第三方库”。
- 接下来系统将上面生成的dex、资源包以及其他资源通过apkbuilder生成初始的APK文件包。注意：此时这个APK还没有经过签名和优化。
- 签名可以采用的工具很多，如Jarsigner或者其他类似的工具。如果是在Debug模式下，签名所用的keystore是系统自带的默认值；否则开发者需要提供自己的私钥以完成签名过程。
- 最后将上述签名后的APK通过zipalign进行优化。优化的目的是提高程序的加载和运行速度——基本原理是对APK包中的数据进行边界对齐，从而加快读取和处理过程。这也同时解释了其名称“zip”+“align”的由来。

至此，我们已经熟悉整个APK编译的流程，为下一节重点分析应用程序的签名打下了基础。

20.4　信息安全基础概述

在讲解Android应用程序的签名前，我们有必要补充了解信息安全与密码学（Information security and cryptography）的一些基础知识，这样读者对后面的学习就能“轻车熟路”了。

相信读者在生活中多多少少都已经接触过密码学的知识。比如我们在浏览网页，特别是一些银行官方网站时，经常会看到“http”协议已经悄然变成了“https”。再如个人电子签名，它的权威性已经得到了广泛的认可，并慢慢取代传统的签名方式而具有法律效力了。这些技术的迅速发展，都得益于密码和安全学的不断突破和创新。

安全是一个抽象的概念。换句话说，什么样的环境才是“安全”的呢？我们先来看看Cryptography的一个经典解释，引用自《Handbook of Applied Cryptography》一书：

Cryptography is the study of mathematical techniques related to aspects of information security such as confidentiality, data integrity, entity authentication, and data origin authentication.

从中可以看出，密码与安全学的几个基础目标是：

- Confidentiality；
- Data Integrity；
- Authentication；
- Non-repudiation。

这样说读者可能会觉得艰涩难懂，下面举个例子以帮助大家理解。假设有3个人，分别是小白（WHITE）、小红（RED）和小黑（BLACK）。从名称上不难看出我们给它们赋予的角色：小白和小红是“善良”的通信双方；而小黑则是“坏人”（Bad Guy，Adversary），如图20-2所示。

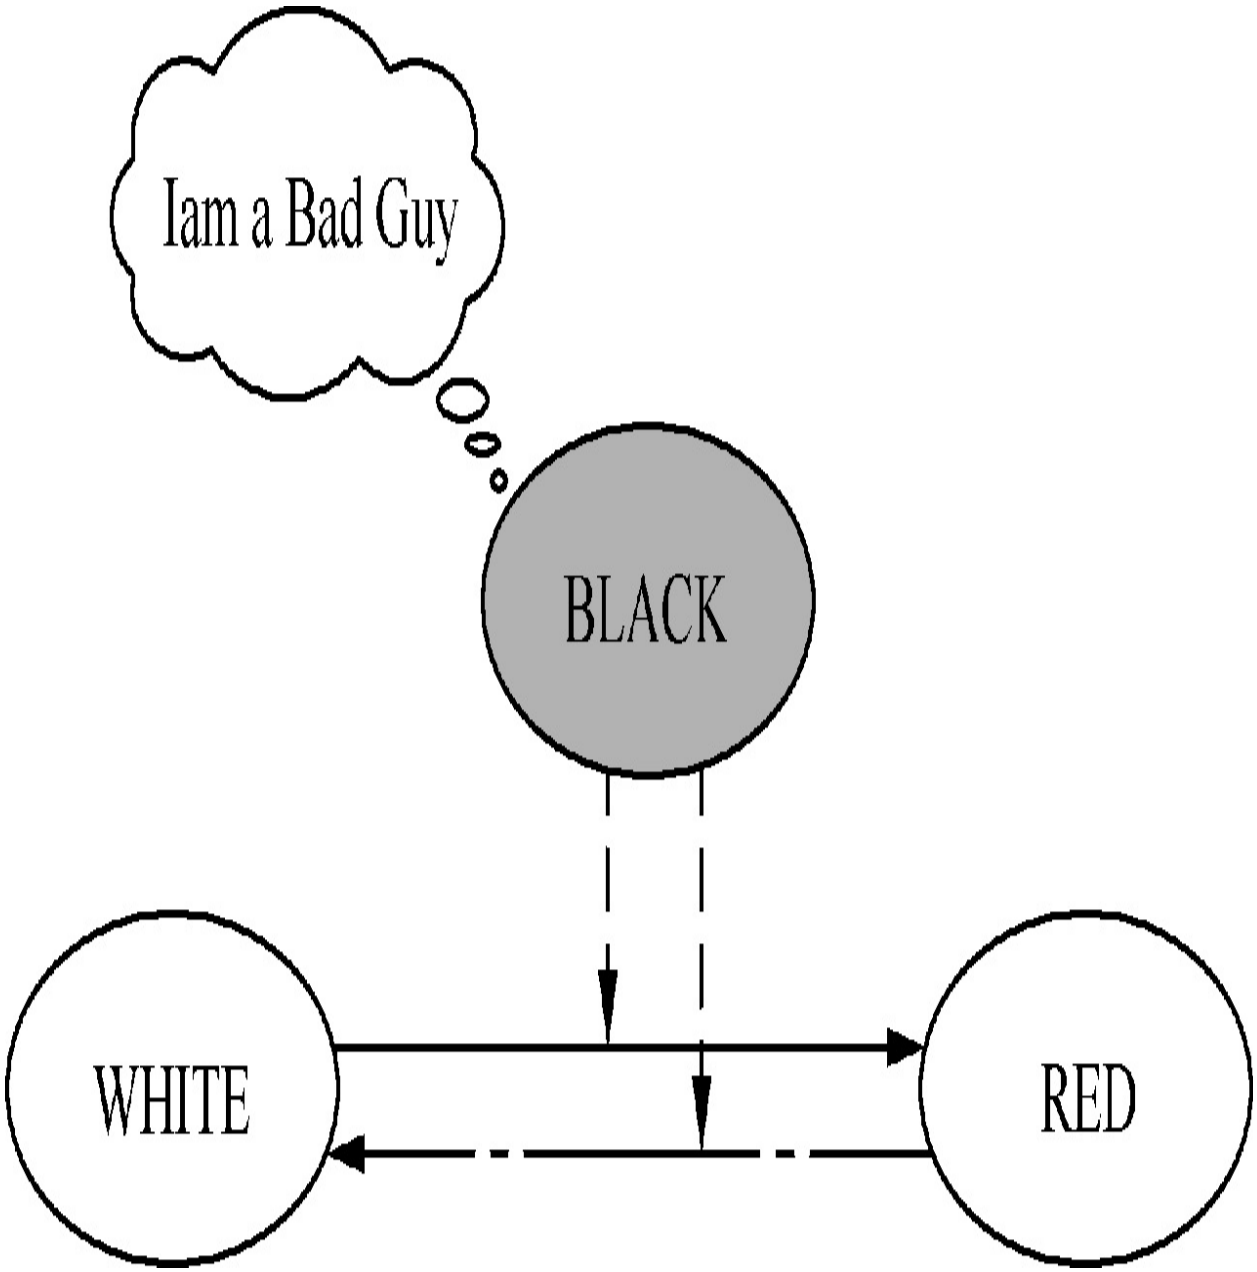

▲图20-2 信息安全中的典型场景

我们的目的就是保证小白和小红的对话能顺利而安全地进行。按照场景的开展顺序，读者可以来推测下将会发生哪些安全隐患。

1．Authentication

假设是小白发起的对话请求，那么首要的一个问题就是：小白怎么知道和它建立连接的是小红。或者反过来说，小红又如何确定对方是小

白呢？

这是安全学中一个非常重要的研究课题，即Authentication。如果场景中的小红不是人类，而是银行服务器，那么可以想象一下如果小黑冒充Bank Server而和小白建立连接，后果将是非常严重的。小黑可以模仿银行的登录界面来轻松骗取小白的账户密码，然后实施各种侵害小白权益的行为。

因而在通信双方建立连接时，必须做相应的身份认证，以保证两端的会话者都是合法的（注意：日常生活中用户登录银行的网上银行，大多数情况下只是银行服务器方提供了身份认证）。

2．Confidentiality

现在小白和小红已经建立连接并且可以正常通信了。那么，这样就高枕无忧了吗？显然不是。小黑能做的破坏还很多，比如它可以在小白家的网络线上剪开，安装上监听器以截取双方来往的信息。这时小白和小红间的通信实际上就是图20-3所示的情况。

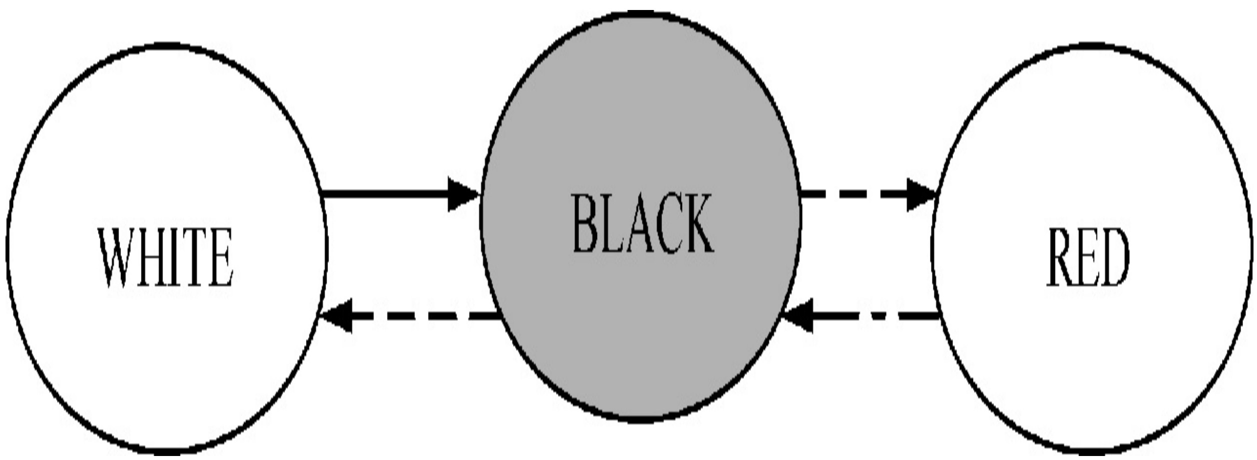

▲图20-3　监听通信双方的往来信息

如果小白和小红在交流中泄露了一些机密信息，如银行卡号、密码等，那么小黑同样可以达到非法目的。解决的办法就是将通信双方的内容进行加密处理，这就是Confidentiality所要解决的问题。

3．Data Integrity

至此，小白和小红的安全性又得到了进一步保障——它们现在已经建立了连接，确认了双方的身份，并且通信数据也已经得到加密，保证小黑无法破解其中的内容。不过这并不代表小黑就无技可施了。虽然小黑没有办法破解监听到的内容，但它仍然可以篡改这些信息，如图20-4所示。

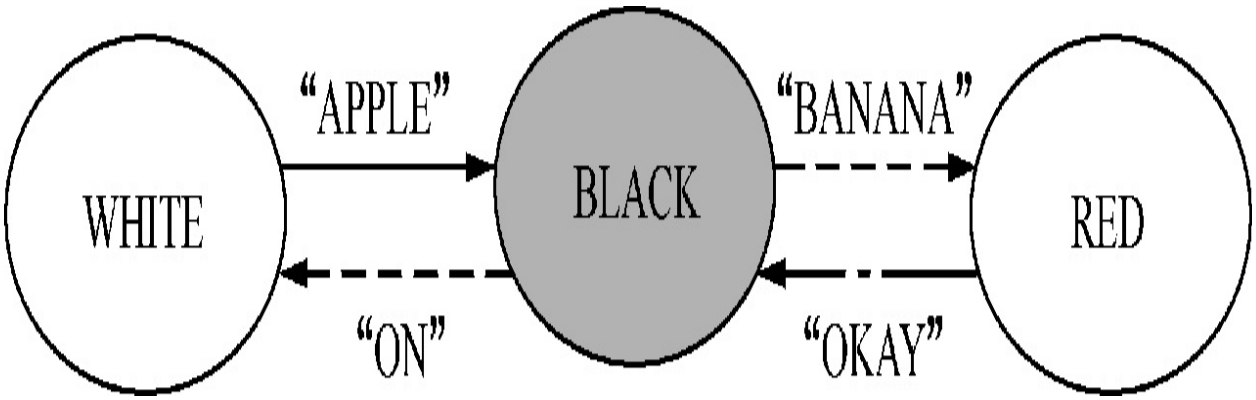

▲图20-4　篡改通信双方的信息

注意

上面这个图例只是示意BLACK可以对通信内容进行篡改，并不是它真的可以获悉通信内容中有“APPLE”或者“OKAY”这些字眼（因为这些数据已经被做了加密处理）。

那么，如何保证内容不被篡改呢？可以肯定地说，做不到，或者在很多场合下做不到。比如小白是在家里通过有线宽带上网，如果没有办法阻止小黑在线路上安装监听器，当然也就无法保证通信数据不被恶意更改。

我们所能做的，就是当数据被篡改时双方可以察觉到这种变化。也就是说，保证通信的发送端和接收端数据的“完整性”，这就是Integrity要解决的问题。

4．Non-repudiation

通过上面的努力，小白和小红终于可以将小黑的破坏抛之脑后了。不过“攘外”以后，“安内”的问题就出现了。假设有这样一个场景：

小白和小红在通信时约定了某项工程的金额，但是没过几天，小红就不认账了，并否认曾经做出的承诺。传统的解决方法里，双方在某项协商达成一致时必须“白纸黑字”签订合同。那么在网络信息通信中，是否也有类似的实现手段呢？

这就是“Non-repudiation”所要达到的目的。它将保证任何一方的承诺都是“无可抵赖和篡改”的，以保证对方的权益。

上面我们以实例的形式分析了信息安全中所面临的4类基础问题（实际上还有第五类问题，即“Availability”，用以衡量某项服务的可用性和可访问性。比如网站在大流量访问下是否可以正常运转。顺便提一下，在密码学领域发表论文时，一个惯例就是要明确指明你的Paper解决了上述问题中的哪一类或几类），接下来就需要从数学原理的角度来思考如何具体解决这些问题。

信息安全学的基础是数学，而其中的关键点总结起来有3个，即：

- Encryption（加密）；
- Decryption（解密）。

加解密算法发展到今天种类已经相当繁多，大的方向可以分为对称和非对称两种。

- Hash（哈希散列）。

简单来讲，Hash就是将不定长度的输入变成定长输出的一个过程。

我们先来看看加密、解密和哈希的一些基础知识。

5．对称算法（Symmetric Algorithm）

如果加密和解密过程所用的密钥完全一样（单钥密码体系），就是对称算法。这是一种传统的加密方式，从密码学发展早期就已经存在（当然，随着科技的发展，其算法的具体实现方式仍在不断演进中）。另外，我们在日常生活中其实也随处可见对称加密的方式，如大家家里的门锁就是单钥系统——因为外出锁门时和回家开门时所用的是完全一样的同一把钥匙。对称加密算法通常速度很快，可以应用于大数据量加密的场合。

当前密码学中常用的对称算法包括DES，AES等。

传统对称算法的一个缺点是不利于传输，如图20-5所示。

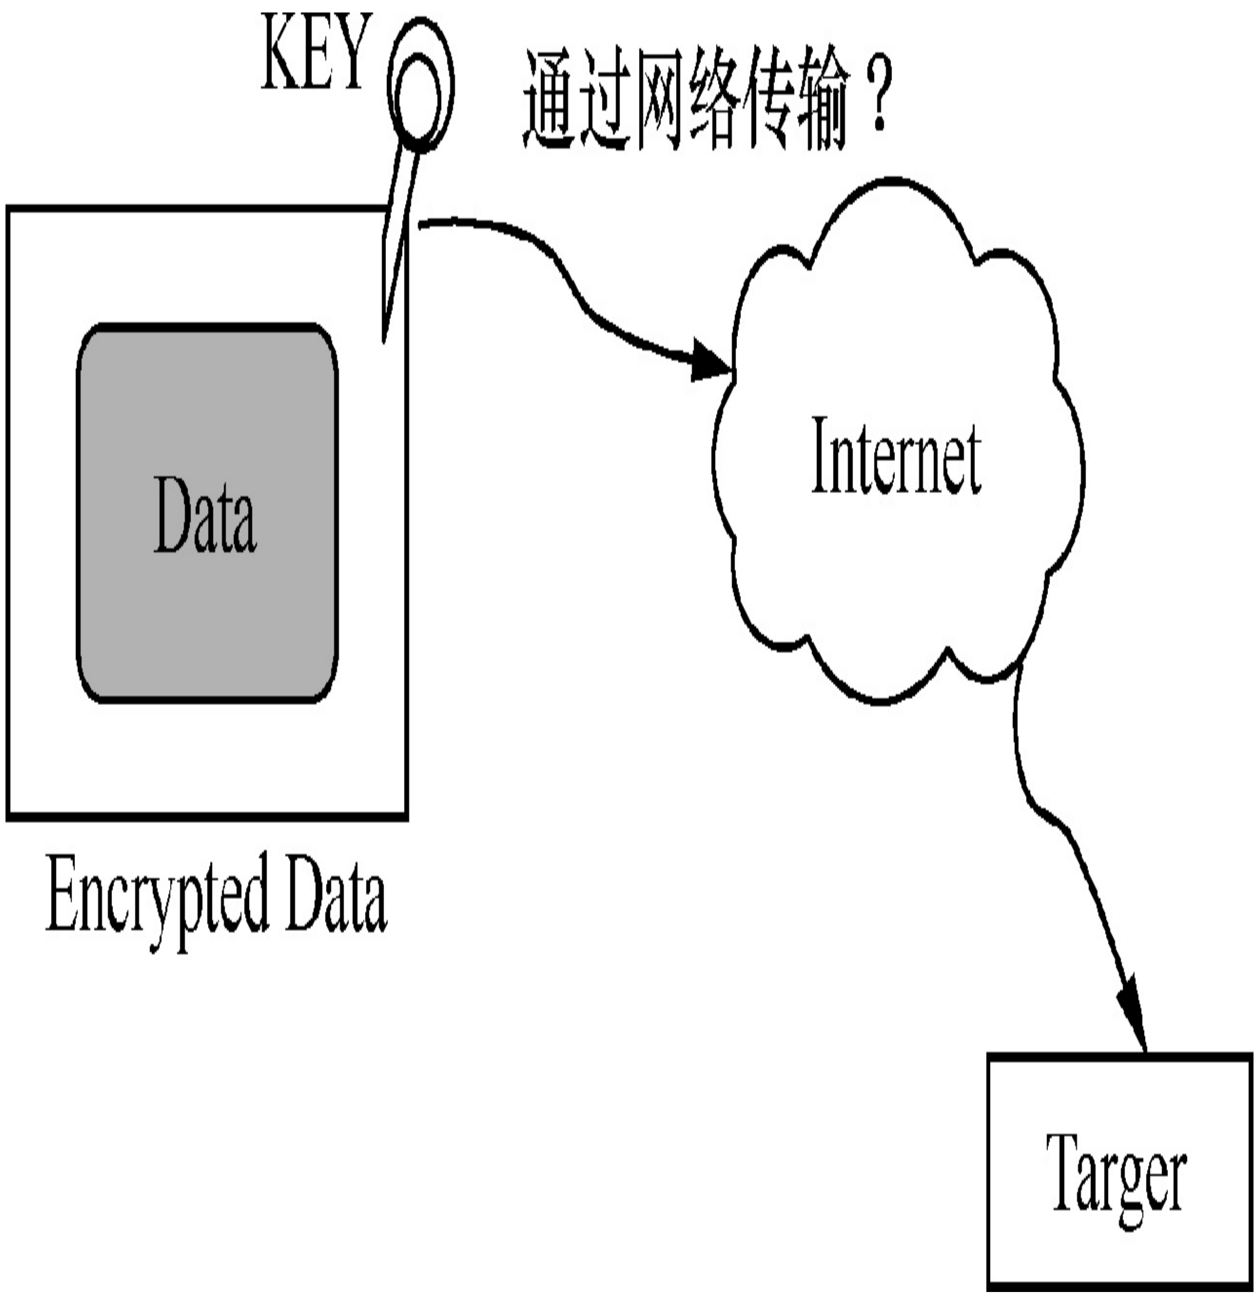

▲图20-5 对称算法的密钥传输问题

我们来设想这样一个场景：小白想邮寄一封密信给小红，为了防止被小黑窃取信件内容，它首先将信放入盒子中，然后加上了一把锁后再邮寄出去。这样确实能保证小黑无法浏览到信的内容，却

也引出了一个致命的问题，即小红也同样没有办法阅读信件的内容，因为它和小黑一样没有锁的钥匙。

那么将钥匙和盒子一起寄过去？显然这样的方式是很愚蠢的，并没有起到任何保护密信的作用。直接寄送密钥是行不通的，于是科学家们开始思考，是否能两边协商出一个共同的密钥？这确实是一个好主意，不过小黑对于这个“协商”过程，也肯定是知晓的（在没有加密前，所有信息都是明文传送，小黑可以轻易获取两方正在进行的任何沟通）。因而这个方案成功的前提是，如何绕过小黑来完成协商过程。

网络传输过程中的信息小黑是能获知的。换个角度来思考这句话，就是通信双方的本地数据（比如小白和小红的本地计算机里内存的数据），它是没有办法得到的。整个协商过程的突破口就在这里，下面以著名的DH（Diffie-Hellman）算法为例来解释这个实现过程。

- 小白和小红首先需要有两个公共的值g和p。因为是公开的，小黑也可以得到这两个数值。
- 小白在本地产生一个私密数值a，小红也同样产生一个私密数值b。
- 小白通过公式Y1=g^a mod p计算出自己的Y值，小红也根据同样的公式算出它的Y2=g^b mod p。
- 然后小白和小红互换它们的Y值。
- 小白计算出通信所需要采用的密钥Key1=(Y2)^a=(g^b mod p)^a=g^(ab)mod p，而小红这边计算出的密钥Key2=(Y1)^b=(g^a mod p)^b= g^(ab)mod p=Key1。

这样一来，它们就协商出共同的Key值了。那么这一过程中，小黑都获取了哪些数据呢？很明显，在网络中传输的值是g，p，Y1和Y2，这其中并没有Key1或者Key2，而计算密钥Key所需的关键数值a或者b，也没有被直接传送。因为Y值计算公式的不可逆性，小黑绝不可能从中推导出a或者b值。

因此我们可以得出一个完美的结论——整个密钥协商过程是安全可靠的。

6．公钥算法/不对称算法（Public-key Algorithm）

公钥算法的核心是加密和解密所用的密钥不是同一个，我们分别称

之为公钥和私钥的Key。一般情况下，数据用私钥/公钥进行加密，然后通过匹配的公钥/私钥解密（其中的数学推导过程我们不做深入分析，有兴趣的读者可以自行查阅相关资料）。公钥是所有人都可以获知的，私钥则由个人自己保存，如图20-6所示。

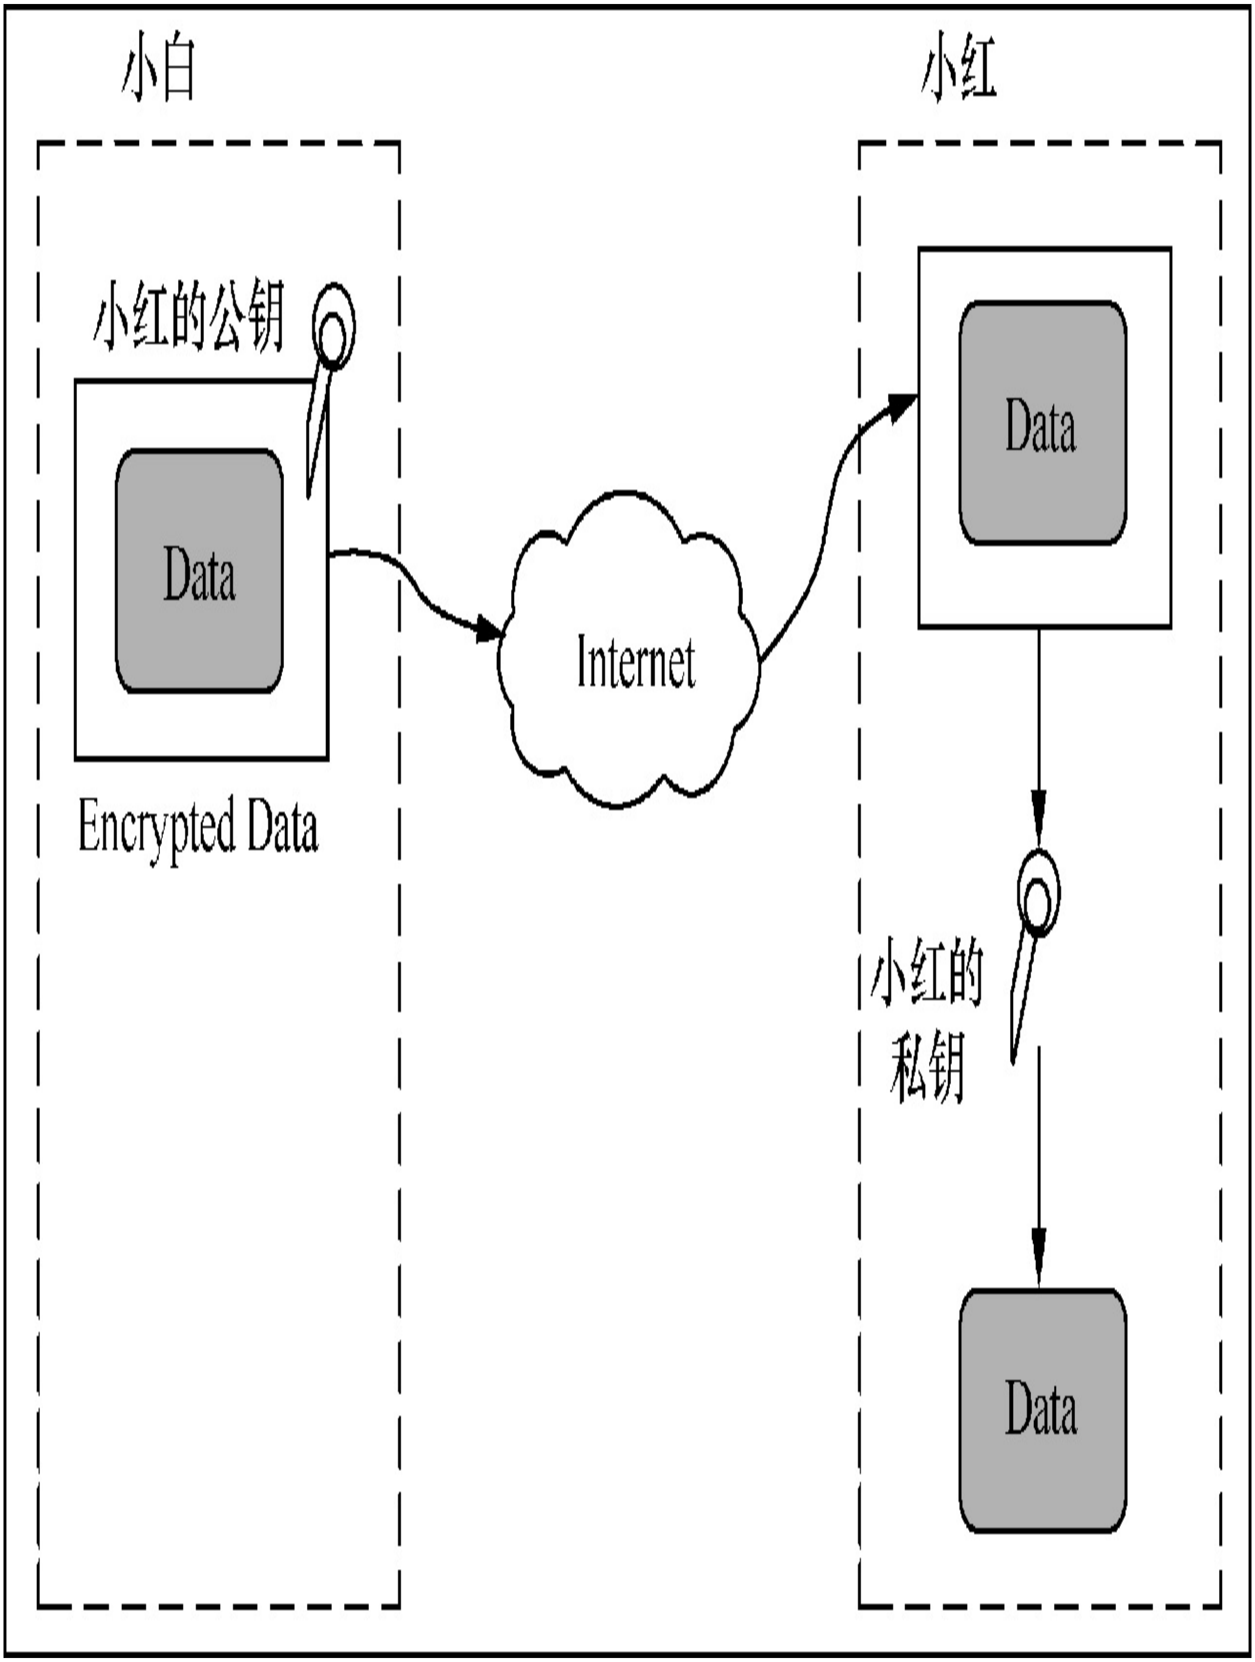
小白
小红
小红的公钥
Data
Encrypted Data
Internet
Data
小红的
私钥
Data

▲图20-6　公钥算法应用（1/2）

通过图20-6所示的方法，小白成功地将数据安全地传送给小红。因为小黑并没有小红的私钥，所以它无论如何也无法破解数据的内容。而另外，因为公钥是所有人都可见的，就避免了对称算法中密钥传输的难题。

图20-6我们使用的是接收方的公钥来加密数据，如果反其道而行之，用发送方的私钥进行加密，又会是什么样的情况呢？如图20-7所示。

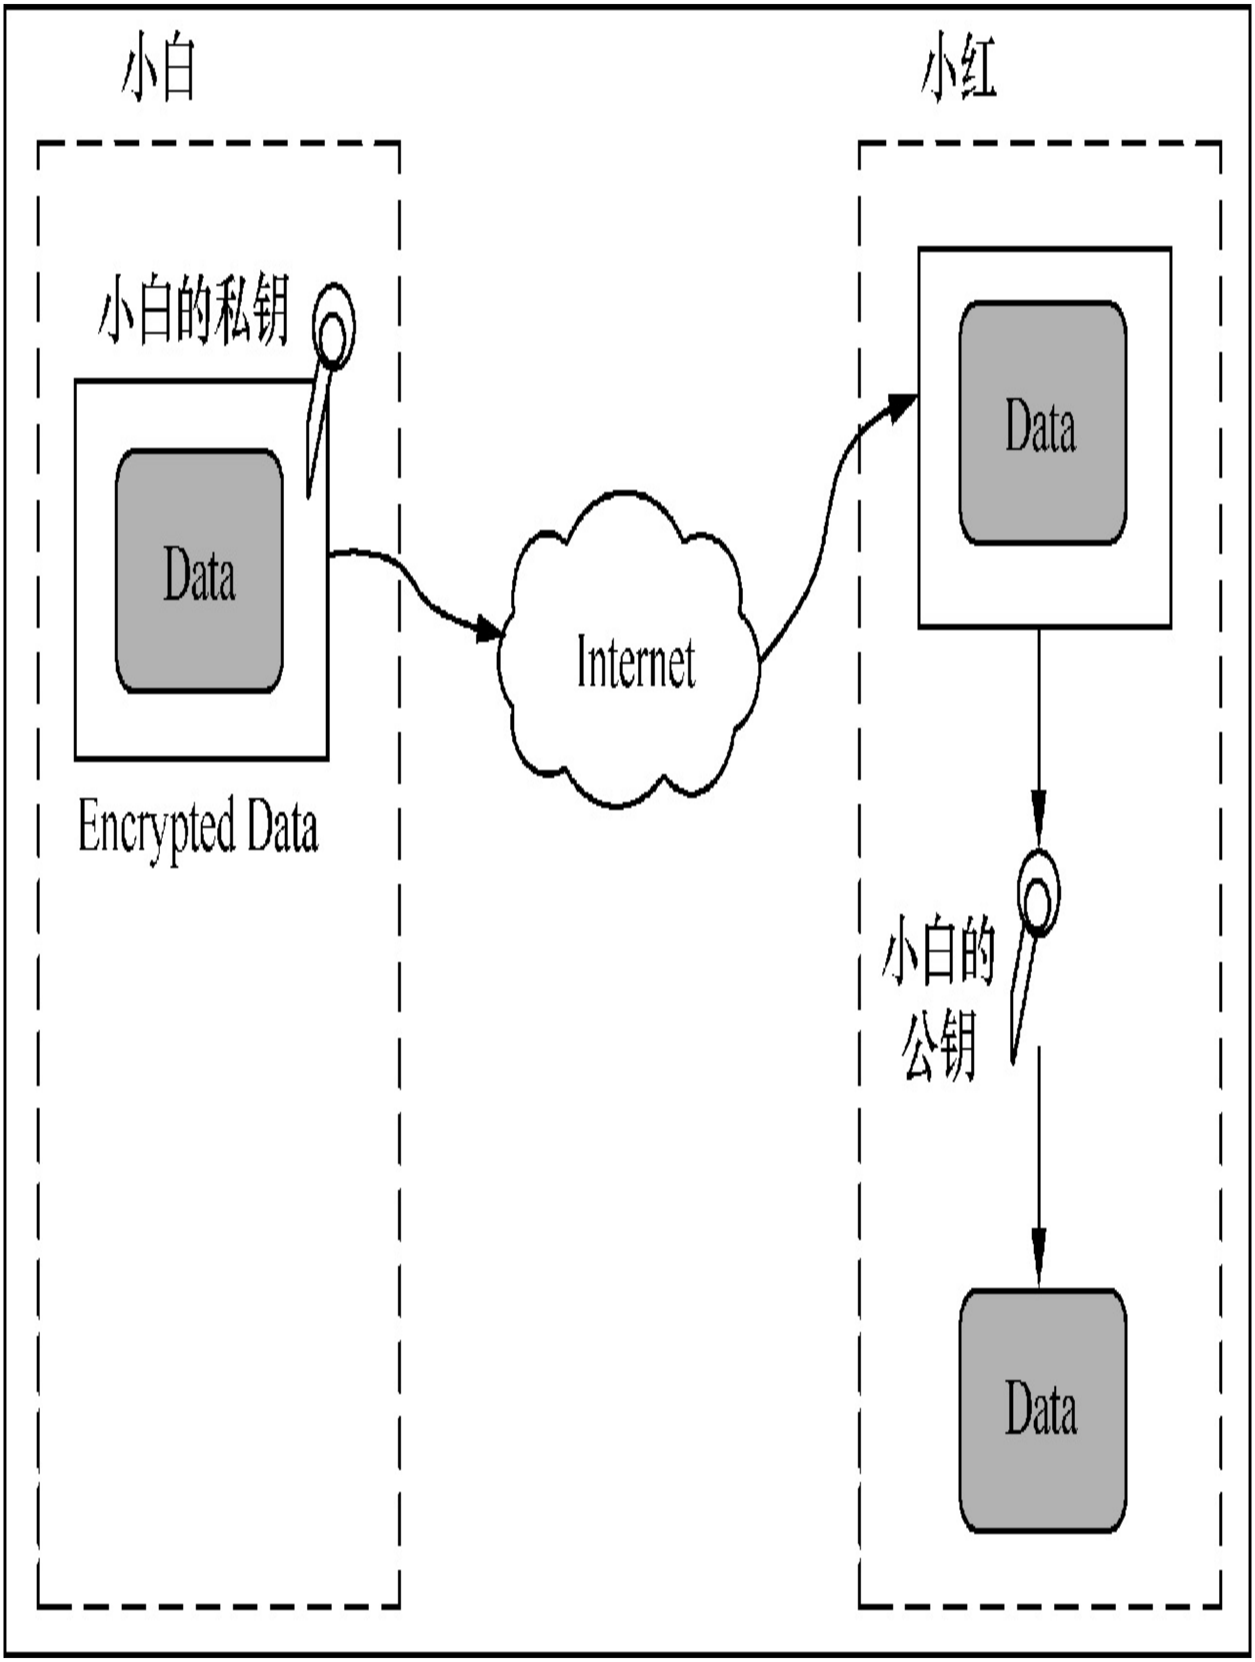

小白
小红
小白的私钥
Data
Encrypted Data
Internet
Data
小白的
公钥
Data

▲图20-7　公钥算法应用（2/2）

读者可能会觉得有点奇怪，既然公钥是大家都能获取到的，而且可以解密，那么数据还有什么安全性可言。请耐心接着往下阅读，答案很快就会揭晓了。

常用的公钥算法包括RSA和DSA等。

7．哈希算法（Hash Algorithm）

学习过数据结构的读者一定对哈希不陌生，因为利用哈希表进行信息查找也是常用的算法之一。Hash的作用就是将任意长度的二进制值映射为固定长度的最终值。从概率学的角度而言，两个不同的输入值经过Hash算法后绝对是有可能发生碰撞的。因而算法的好坏很大程度上取决于它能否最大限度地降低这种冲突。另外，哈希算法要求整个转换过程具有随机性——即就算两个输入值仅有非常小的差异，其输出值也应该有“天壤之别”。这样的设计在信息安全中有重要意义，可以有效防止非法人员通过不断推测来获知明文信息。

Hash算法除了用于查找外，还有很多其他方面的应用，如消息摘要、数字签名等。常见的哈希算法有MD5、SHA、SHA-1、SHA-256、SHA384和SHA-512等。

加解密和哈希算法是解决信息安全领域众多问题的基础。下面再回头来看看小白、小红之前碰到的4个安全隐患。

- Authentication

我们知道在公钥算法中，私钥由个人自己保存，并且其他所有人都是无法获知的。这就给Authentication提供了理论依据。比如在这个场景中，小白确认对方是不是小红的依据，就在于对方有没有拥有小红的私钥。具体如何操作呢？典型的做法如下：

- 小白用小红的公钥去加密一段数据，然后传给对方；
- 对方用私钥解出明文数据，并返还给小白；
- 小白比较对方提供的明文是否和自己本地保存的数据匹配。

因为公钥加密过的数据只能由私钥解密，所以只要对方能正确解密出原始数据，就可以认定它是小红。

不过实际的过程要复杂些。想象一下，如果小黑是等到小白和小红做完了认证后再介入呢？因为此时小白已经完全相信对方是小红了，很有可能会造成安全问题。所以认证的同时，也要综合考虑双方的数据加密，这样才不会让非法人员有机可乘。

- Confidentiality

加密协商通常和上述的认证过程综合进行。如果是大数据量的传送，一般情况下需要使用DH算法协商出对称密钥；而对于一些小量的数据，可以使用双方的公钥进行加密。

- Data Integrity

单纯的加解密算法无法解决完整性认证，所以我们还需要引入Hash算法，流程如图20-8所示。

上图的主要步骤如下：

- 发送方首先对数据进行哈希处理，得到一个Hash值；
- 发送方将数据和哈希值进行加密，并传送到接收方；
- 接收方解密后，先对数据进行同样的哈希处理，得到另一个Hash值；
- 接收方将收到的哈希值和上一步中得到的Hash值进行比较，判断数据传递过程中是否被篡改。
- Non-repudiation

Non-repudiation直译过来就是“无法否认”。在认证过程中，我们采用的原理是“只有拥有私钥的人才能解密用公钥加密过的数据”。与此类似，“只有用私钥加密的数据才能用公钥解开”——这就是数字签名所依据的理论基础。

假设小白认可了一份合同，并使用自己的私钥对其进行了加密，那么如果后期发生纠纷，就可以使用小白的公钥对这份文件进行解密。由于私钥的唯一性，小白就没有办法抵赖经它签过名的内容。

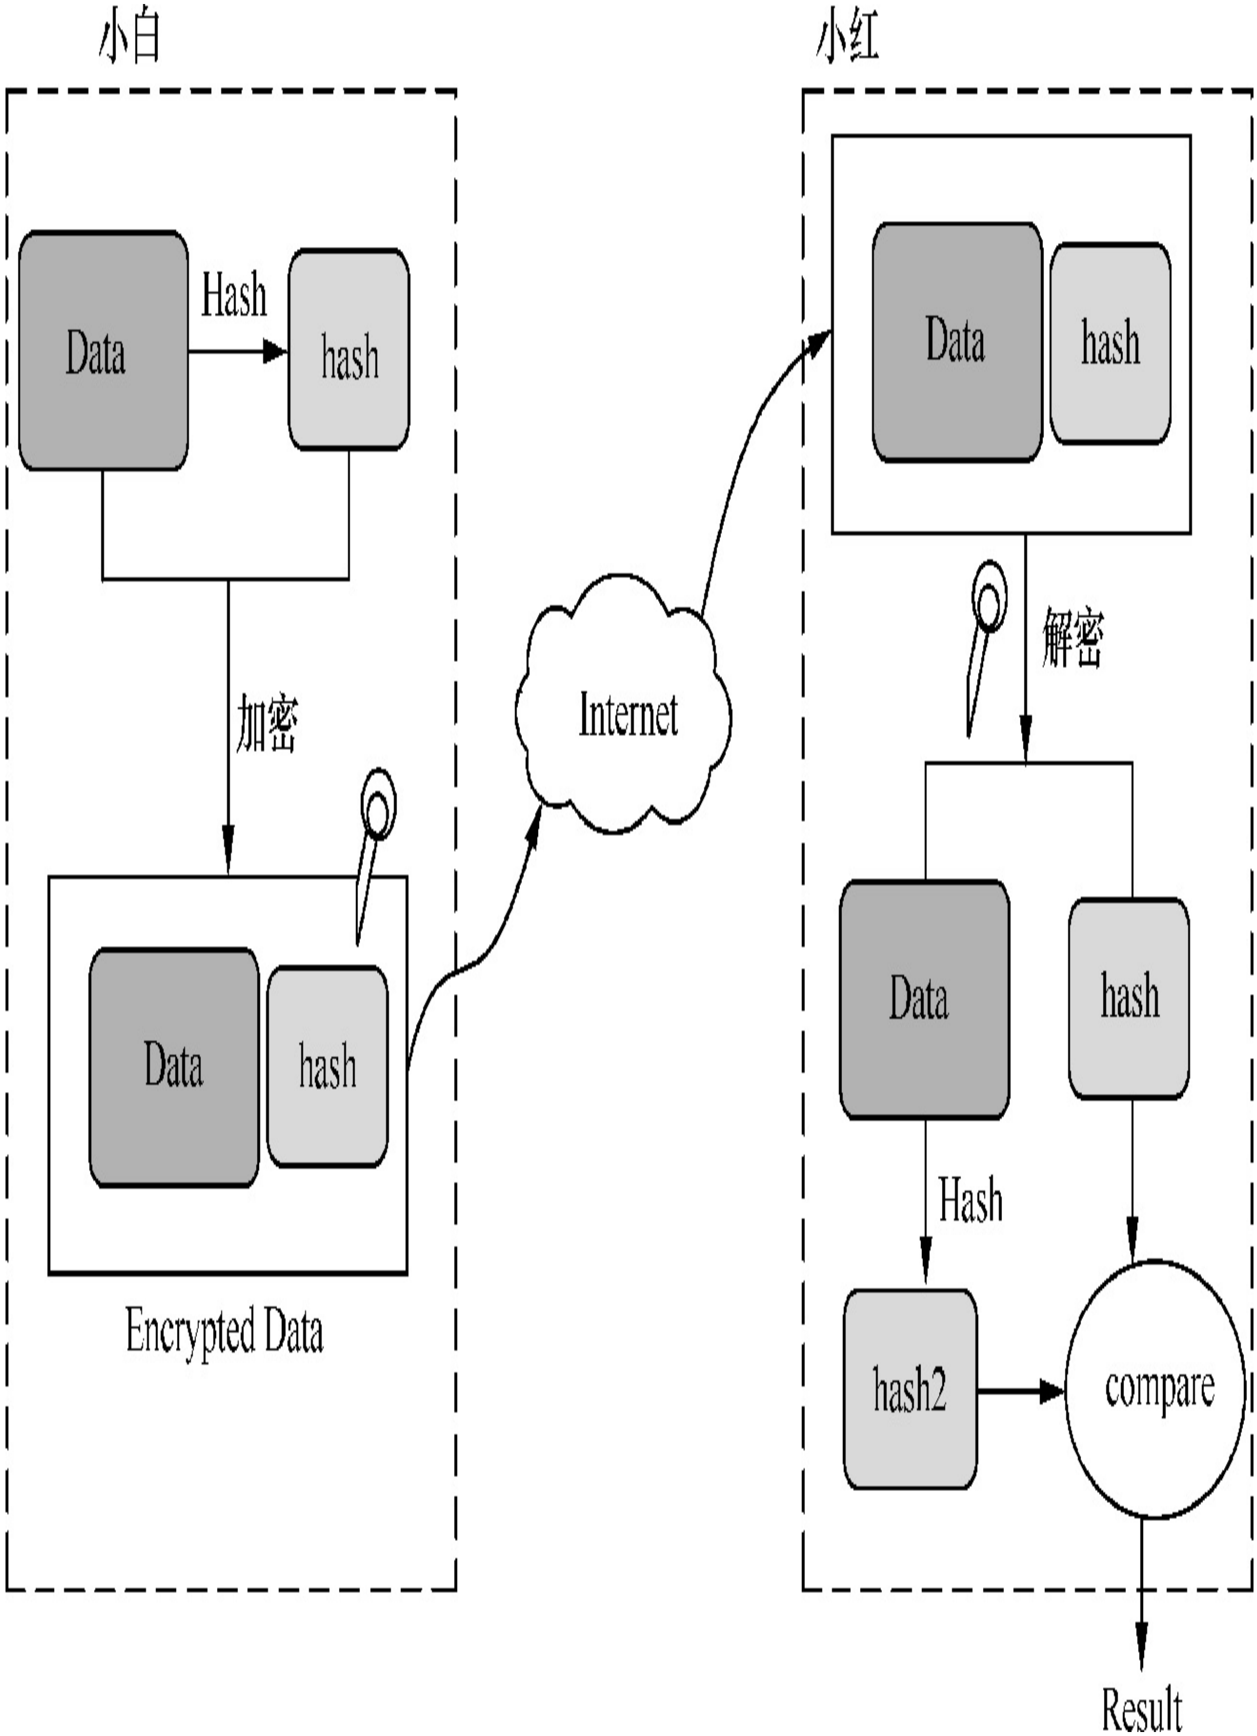

小白
小红
Data
Hash
hash
加密
Data
hash
Encrypted Data
Internet
Data
hash
解密
Data
hash
Hash
hash2
compare
Result

▲图20-8　数据完整性的验证过程

不过在实际应用中，情况通常不会这么简单。比如谁能知道小白的公钥是哪一个？为了解决这个问题，就需要有一个公共的服务中心来保管和提供权威的公钥查询功能——这就是CA（Certificate Authority）的职责所在。

目前市面上已有不少CA机构能提供数字证书的颁发和查询，而且其中一部分是免费的。当用户需要验证某份公钥是否属于它所要建立连接的机构或个人时，就可以向CA发起请求。在浏览网页的过程中，这一过程通常由浏览器自动帮你完成。比如你在访问Https开头的网站时，通常服务器会发送一份经过CA签名过的证书来证明自己就是你所要找的目标，这时浏览器就需要自动去认证这一证书的真伪。假如浏览器已经有该CA的证书，表示它信任这个组织，那么它就可以使用CA的公钥去解密服务器的证书并做完整性测试。如果一切顺利，浏览器就可以相信服务器里所提供的公钥和身份信息，而后使用这一公钥与服务器进行对话。

本小节我们从一个典型的信息对话场景入手，逐步引出所有可能发生的安全隐患。然后结合密码学的基础理论（加解密算法、哈希算法），详细讲解了这些安全问题的应对之策——其中提到的多种解决方案都是应用密码学中的典型应用。

下一小节我们将向续者讲述Android系统又是如何保证应用程序的安全的。

20.5 应用程序签名

Android系统中的应用程序签名有如下几个特点。

- 所有的Android应用程序都需要被签名，不论它是debug还是release版本。可以参看本章的开头几个小节。
- 可以采用自签名的形式。也就是说，可以不需要上一小节提到的CA认证。
- 系统只在安装过程中检查证书的有效性。如果应用程序安装以后证书才过期，并不会影响它的使用。
- 可以使用Keytool和Jarsigner来完成签名过程，然后还需要使用zipalign对apk文件进行优化。可以参阅本章开头几个小节。
- 建议开发者对自己研发的所有应用程序采用统一的证书。
- 当应用程序升级时，系统会比较新旧版本的证书是否一致。如果证书一致，升级才能顺利进行；否则安装将失败。当然，你也可以更换新版本的包名，这时系统会把它当成另外一个应用程序进行安装。
- 采用相同签名的应用程序允许被安排在同一个进程中运行。
- 采用相同签名的应用程序间可以根据特殊权限进行代码和数据的共享。

接下来我们分别介绍Debug和Release模式下的签名过程。其中，Debug模式比较简单，因此只是做简单介绍。

Debug Mode

这个模式下的签名过程是由系统自动完成的。因为采用的是默认的keystore，用户不需要特地输入密码等信息。签名所需用到的工具Keytool和Jarsinger都是由JDK提供的，因此需要保证JAVA_HOME环境变量的正确性。

默认的签名信息如下：

- Keystore name: "debug.keystore";

- Keystore password: "android";
- Key alias: "androiddebugkey";
- Key password: "android";
- CN: "CN=Android Debug,O=Android,C=US"。

需要注意的是，Debug下所使用的证书也是会过期的，它从生成之日算起只有365天的有效期。一旦超过期限，系统会有类似下面的提示：

```
Debug Certificate expired on 8/4/08 3:43 PM
```

解决的方法就是将debug.keystore文件删除，那么下一次编译时就会再自动生成新的keystore了。存放debug.keystore文件的路径依据不同的操作系统会有所差异。

- Linux和OS X

  ～/.android/

- Windows XP

  C:\Documents and Settings\<user>.android\

- Windows 7

  >C:\Users\<user>.android\

  Release Mode

  Release模式的签名过程相对麻烦一些，如下所示。

- 获取一个私人密钥

可以选择使用Keytool工具生成一个新的密钥。需要特别注意的是，如果发布的应用程序是针对Google Play，那么证书的过期时间必须在2333年10月22日以后。Keytool的使用方法我们这里不做详细介绍，读者可以自行查阅资料了解。

- 编译release版本的应用程序

我们在第一小节已经做过详细介绍，这里不再赘述。

- 利用相关工具对应用程序进行签名

JDK已经提供了Jarsigner来完成签名过程。当然，读者也可以选择其他合适的工具来替代Jarsigner。关于这个工具的详细使用方法，可以参见Oracle官方文档

- 最后对签名后的应用程序进行对齐优化

前面小节我们对Zipalign进行过简单介绍，它保证所有数据能按照特定标准来相对文件开头进行字节对齐。这将在一定程度上提高应用程序的运行速度，如系统可以使用mmap()来读取文件，而不是复制包中的所有数据。Zipalign的语法很简单，范例如下所示：

```
zipalign -v 4  App_name-unaligned.apkApp_name.apk
```

其中，-v开启verbose输出；数值4代表要对齐的字节数（当前只允许填写4）。

后两个APK分别代表了输入和输出。如果需要覆盖原有的APK，还需要加上-f标志。

如果你觉得使用命令行模式效率太低，而且是在Eclipse环境下开发，那么还可以使用ADT提供的Export Wizard来逐步导出有效的APK应用程序（图20-9左半部分）。这种方式可以让你使用已有的keystore进行签名，也允许新创建一个keystore（图20-9右边部分）。

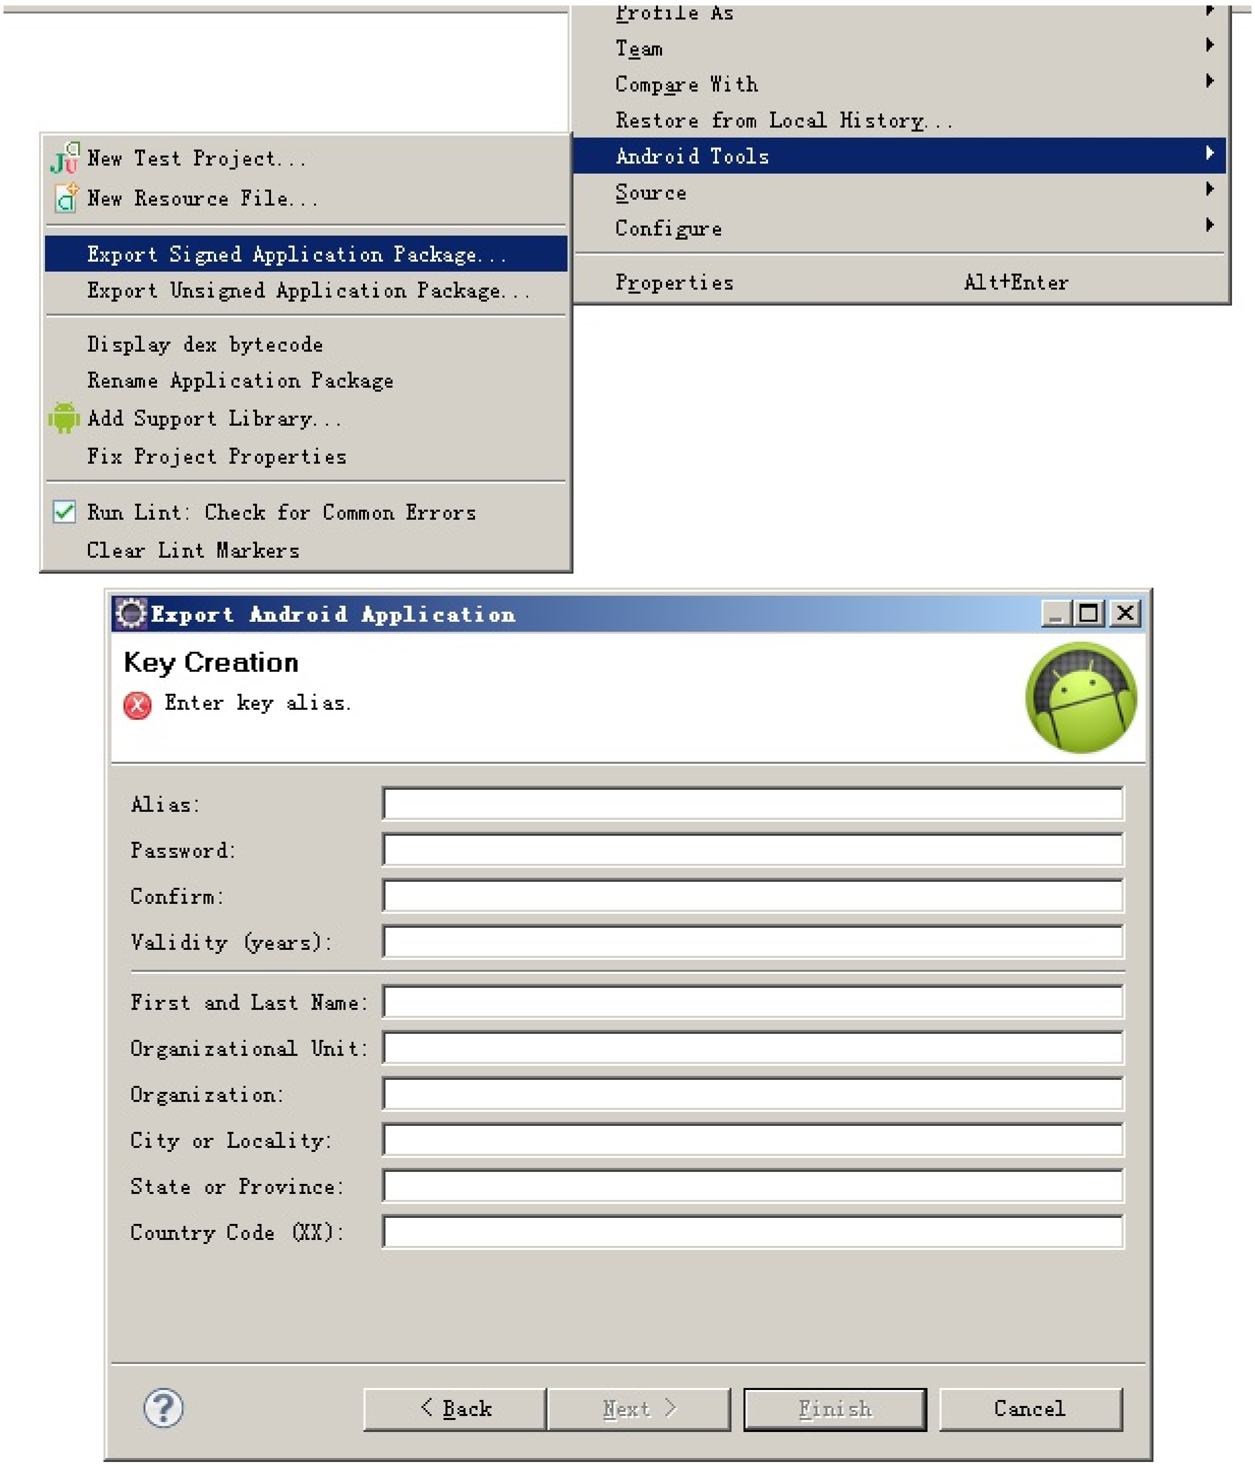

▲图20-9　使用ADT的Export功能导出合法的APK

这时编译系统会对APK应用程序展开更加详细的检查，包括安全（Security）、效率（Performance）、可用性（Usability）等多个方面。默认情况下如果检查过程中发现有错误，程序就会停止APK的导出

操作。你也可以在Preferences->Lint Error Checking中关闭这个检查功能，如图20-10所示。

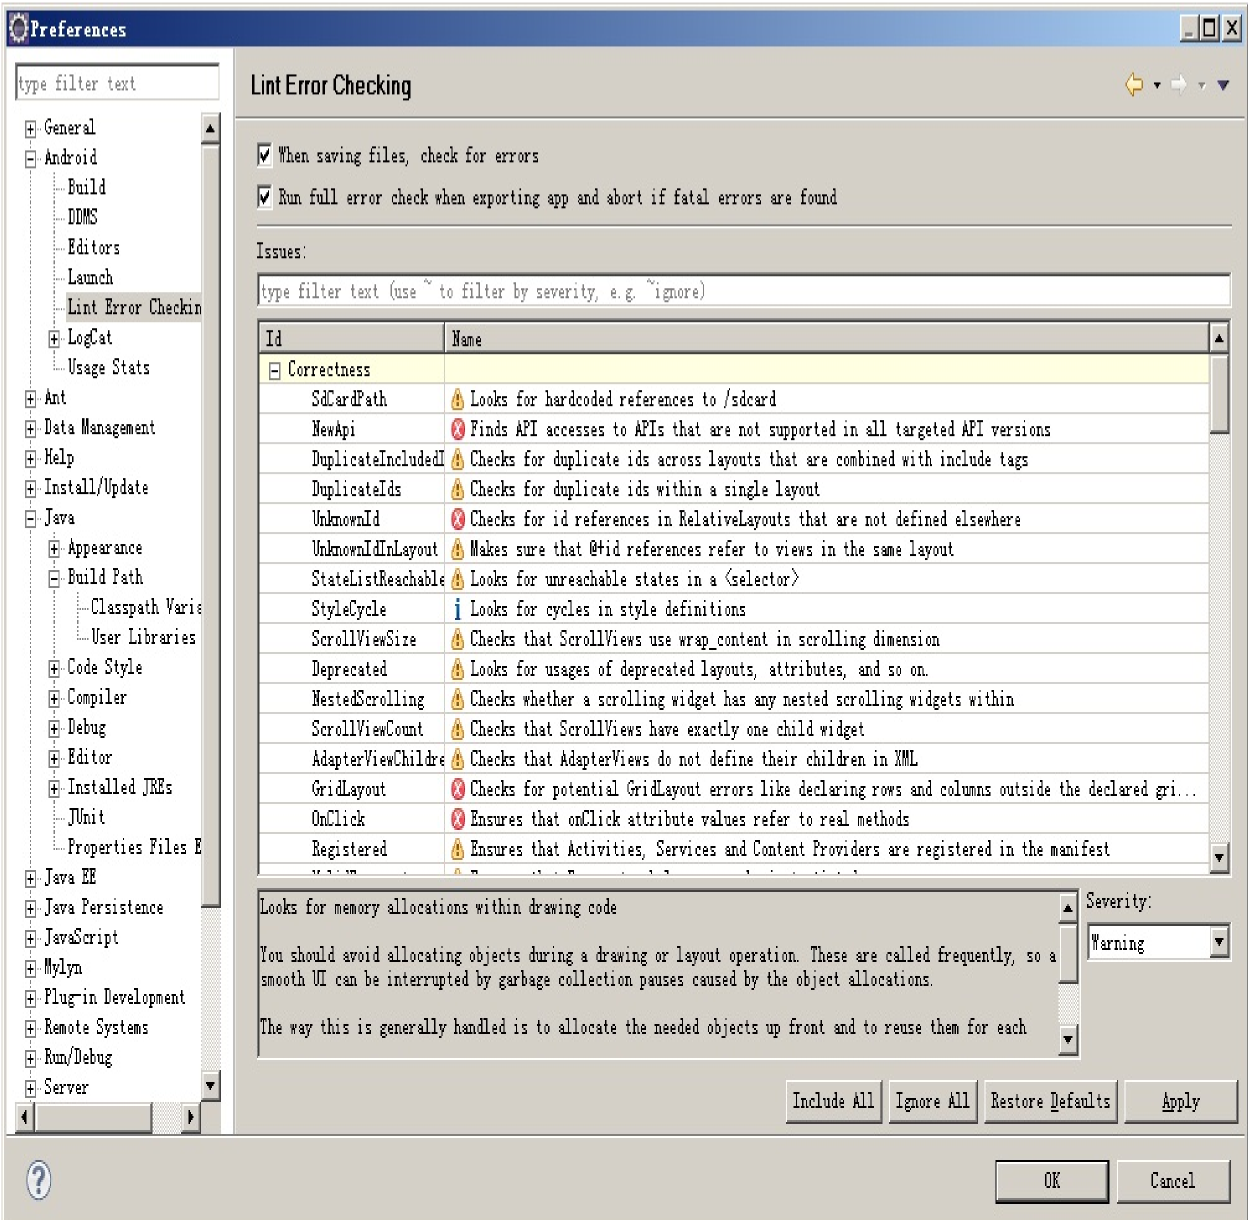

▲图20-10 Lint Error Checking

由此可见，Android系统提供了多种开发方式。而具体选择哪一种，则取决于开发者的习惯以及项目的实际需求。当然，无论是命令行还是图形界面操作，应用程序的编译、打包、签名、对齐这些操作的原理都是不变的。

20.6　应用程序签名源码简析

这一小节我们来简要分析下应用程序签名相关的关键源码。

首先来比较下签名前和签名后APK的区别。图20-11和图20-12分别显示了用Eclipse的“Export Unsigned Application Package”和“Export Singed Application Package”导出来的同一个APK的目录结构。

▲图20-11　未签名的APK目录结构

▲图20-12　签名后的APK目录结构

如果直接安装未签名的APK、adb将会报错，如图20-13所示。

▲图20-13　报错

可以看到，两者间的唯一差别就是META-INF文件夹，其他部分的数据无论大小或者内容都是一样的。关于META-INF我们前几个小节做过简单的介绍，它是专门用来保存应用程序签名和校验等安全信息的目录，通常情况下包括MANIFEST.MF、CERT.SF和CERT.RSA 3个文件。签名和校验过程实际上就是围绕这3个文件展开的，可以用图20-14概括它们之间的关系。

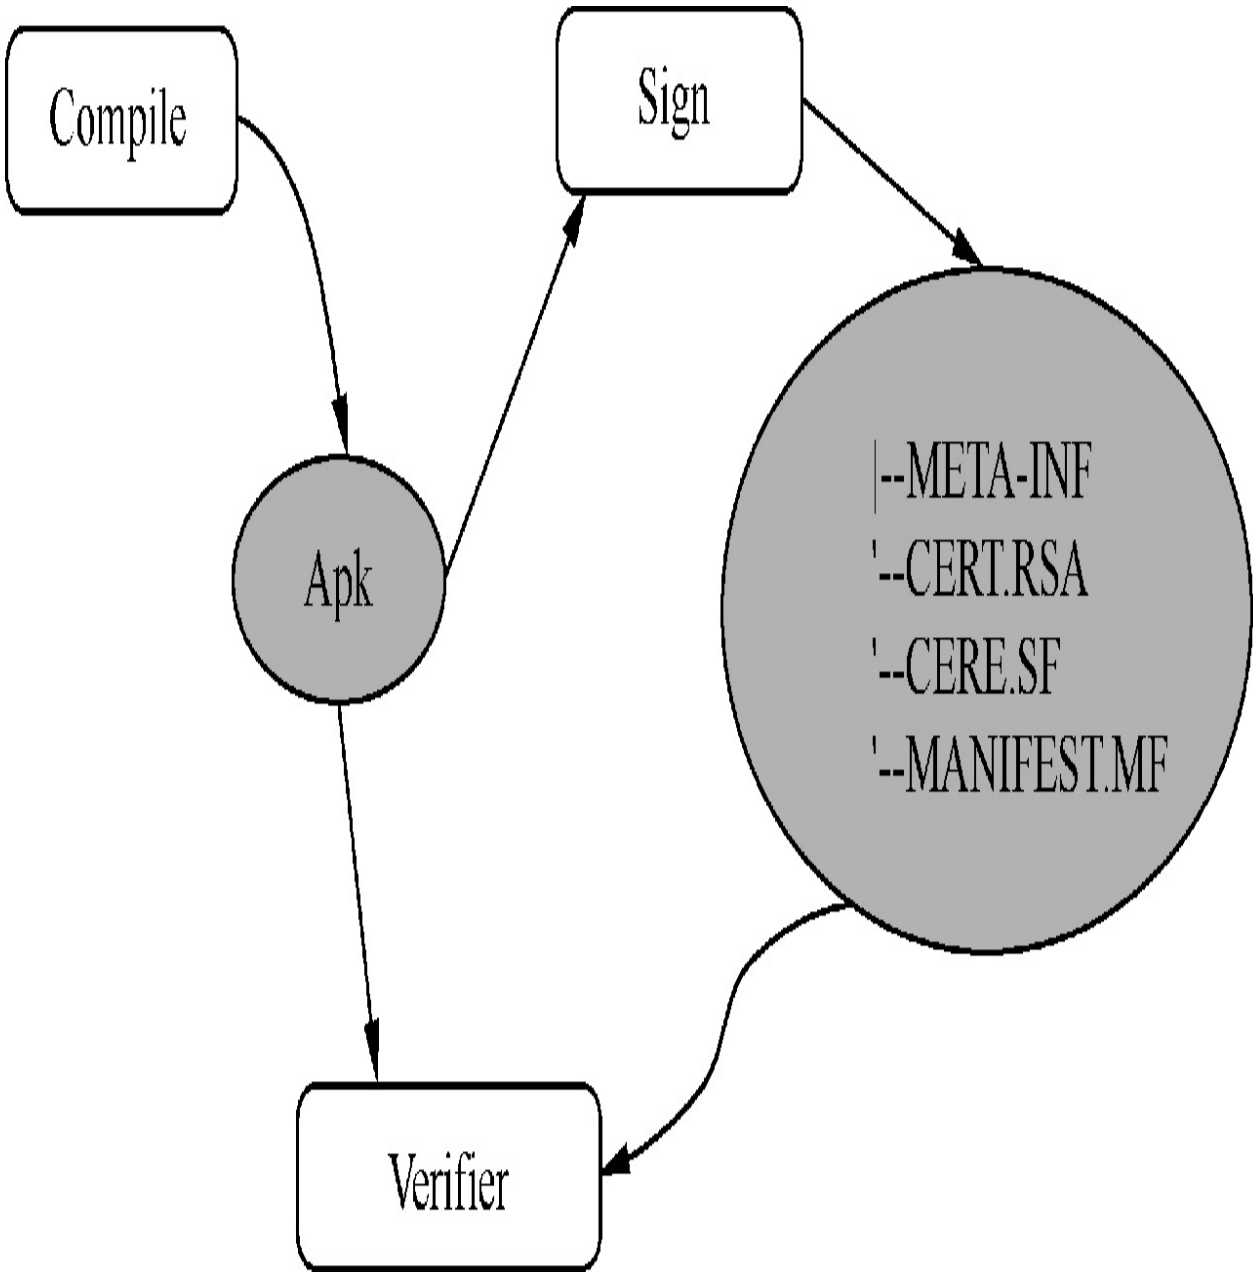

▲图20-14　签名与校验简图

接下来我们将通过分析verifier源码来了解META-INF下各文件的用途以及整个签名校验的大致流程。

当一个应用程序需要安装时，首先Package Manager会对其进行初始化处理。这其中就包含了对签名和文件哈希值的检查，函数流程如图20-15所示。

这其中的逻辑关系比较复杂，主要涉及以下几个类。

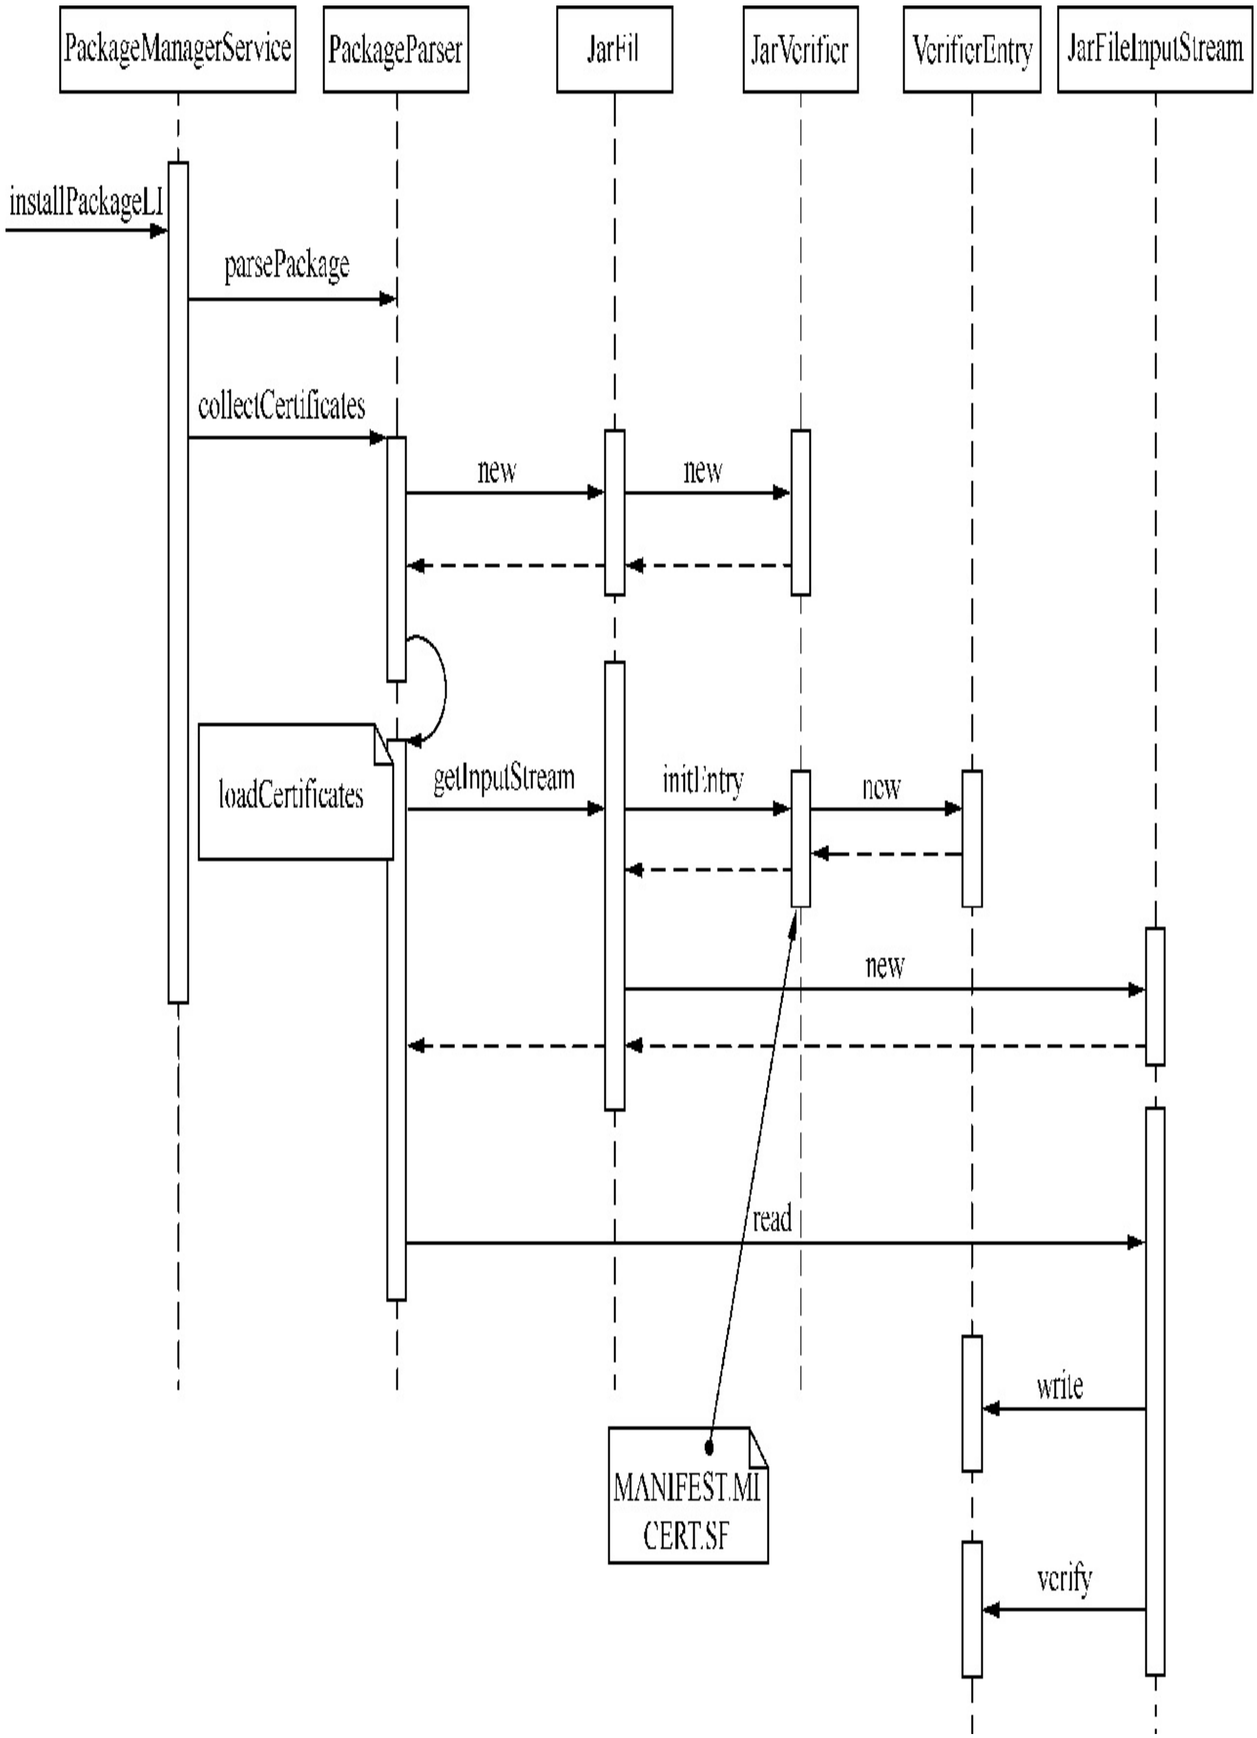
PackageManagerService
PackageParser
JarFil
JarVerifier
VerifierEntry
JarFileInputStream
installPackageLI
parsePackage
collectCertificates
new
new
loadCertificates
getInputStream
initEntry
new
new
read
write
MANIFEST.MI
CERT.SF
verify

▲图20-15　安装应用程序时的安全检查

1．PackageParser

负责解析应用程序包，并完成安全校验；而且整个校验过程是针对APK包中的所有文件逐个进行的，这也同时解释了为什么MANIFEST.MF中为每个文件都提供了hash值。一个典型的MANIFEST.MF文件格式如下所示：

```
/*MANIFEST.MF*/
Manifest-Version: 1.0
Created-By: 1.0 (Android)

Name: res/drawable-ldpi/pty.png
SHA1-Digest: JfxEcu/NKzCCaCsg1rwnOxUBK7U=

Name: res/drawable-ldpi/fm3_down.png
SHA1-Digest: LvoLkSkySbbH79GbuCc+qg311do=

Name: res/drawable-ldpi/signal2.png
SHA1-Digest: yVjMqmIUQ5cKNi/dgyq35o2d3gQ=

Name: res/drawable-ldpi/fm2.png
SHA1-Digest: 9M3S7wzBvE2bJn/ffa1IF+546sk=

Name: res/drawable/key4_select.xml
SHA1-Digest: jj3NmAjUMeqfAQvnl0ijUNHQN9Q=

Name: res/drawable-ldpi/ta_indicate.png
SHA1-Digest: kcqTpfODE7dh1QTsY0miCCZP6lI=
```

安装过程中只要有任何文件的Hash匹配无法通过，整个安装就会终止，并有类似如下的提示：

```
Package *** has no certificates at entry ** ; ignoring!
```

其中的entry即指程序包中发生错误的文件。

我们这里再补充一些密码学的基础知识，这样读者在学习源码时就更容易理解了。以上面MANIFEST.MF中的第一个文件为例，即：

```
Name: res/drawable-ldpi/pty.png
```

```
SHA1-Digest: JfxEcu/NKzCCaCsg1rwnOxUBK7U=
```

计算这个pty.png文件的SHA-1摘要值的步骤如下。

- 根据SHA-1算法得到这个文件的摘要。标准SHA-1的输出位数为160bit。
- 有读者可能会觉得奇怪，既然SHA-1的输出为160位，即20个字节，那么为什么下面的字符串有28个呢？这是因为上述得出的20字节的数据还需要经过BASE64编码。

BASE64的基本规则是将原始数据的3个字符变为4个字符，每6位前加上2位0，所以最终得到的每字节最大值都不会超过64。因为0～63的ASCII码有不可见字符，为了方便起见，算法还会将这64个数值分别对应为固定的可见ASCII字符。

比如经过SHA-1运算后，我们得到如下值：

25FC4472EFCD2B3082682B20D6BC273B15012BB5，一共20个字节。

前3个字节的二进制码为00100101(25) 11111100(FC) 01000100(44)

我们在每6位前都加上两位0，这样就变成：

00 001001 00 011111 00 110001 00 000100

| | | |

十进制 9 31 49 4

根据BASE64表，数值9、31、49和4分别对应可见ASCII字条中的J、f、x和E，这和我们上面看到的MANIFEST.MF中的结果完全一致，因而说明这个pty.png文件没有被篡改过。读者可以依照上面的算法自行计算剩余的几个字符。

2．JarFile

继承自ZipFile，每一个Apk包只对应唯一的JarFile，这也进一步

验证了应用程序包实际上是一个Zip压缩包。它代表了检验过程中的一个整体，真正的匹配工作则由JarVerifier完成，可以参见后面的类图关系。

3．JarVerifier

JarVerifier是各种校验数据的储存仓库，同时它包含了VerifierEntry嵌套类，后者会对每一个文件做具体的检查和匹配工作。

4．VerifierEntry

真正的匹配是在这里完成的。JarVerifier在生成一个VerifierEntry时，会进行一定的初始化，然后JarFileInputStream还会进一步完善其中的数据，然后进行校验。成功后它的Entry将提交JarVerifier进行存储，以备后期查询。

5．JarFileInputStream

继承自InputStream，同时也是JarFile中的嵌套类。

我们再提供一个类图来帮助读者理解，如图20-16所示。

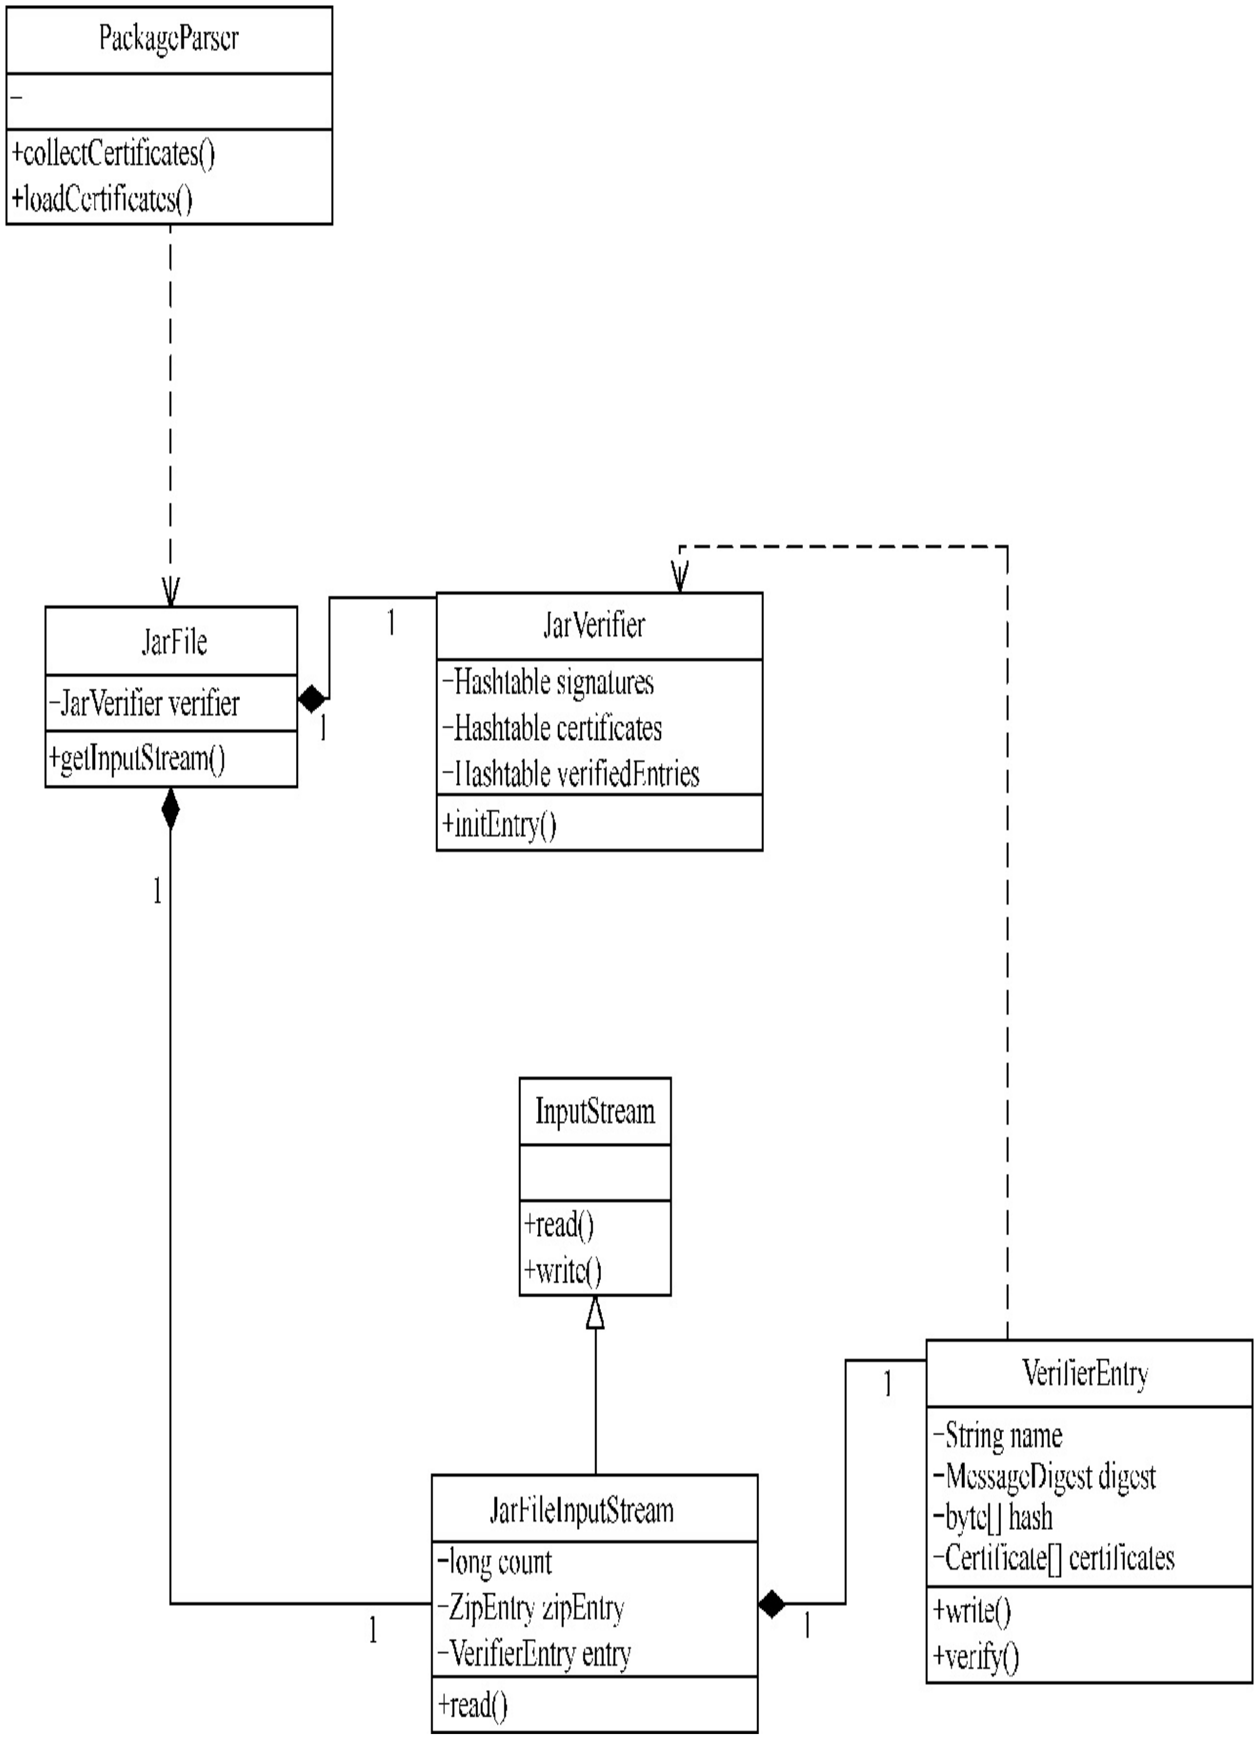
PackageParser
–
+collectCertificates()
+loadCertificates()
JarFile
–JarVerifier verifier
+getInputStream()
JarVerifier
–Hashtable signatures
–Hashtable certificates
–Hashtable verifiedEntries
+initEntry()
InputStream
+read()
+write()
JarFileInputStream
–long count
–ZipEntry zipEntry
–VerifierEntry entry
+read()
VerifierEntry
–String name
–MessageDigest digest
–byte[] hash
–Certificate[] certificates
+write()
+verify()
1
1
1
1
1
1

▲图20-16　安全校验相关类的关系图

接下来我们分析部分重点代码：

```
/*frameworks/base/core/java/android/content/pm/PackageParser.java
public boolean collectCertificates(Package pkg, int flags) {…
     JarFile jarFile = new JarFile(mArchiveSourcePath); /*创建一个、
                                                                   以APK包的
      …
     if ((flags&PARSE_IS_SYSTEM) != 0) {/*如果这个包来源于system ima
                                因而只检查AndroidManifest.xml文件，不用逐个校
         …
     }else{
          Enumeration<JarEntry> entries = jarFile.entries(); //程
          while (entries.hasMoreElements()) {//对包中的所有文件逐一进
          final JarEntry je = entries.nextElement();
          if (je.isDirectory()) continue; //忽略目录
          final String name = je.getName(); //文件名
          if (name.startsWith("META-INF/"))
          continue;
          if (ANDROID_MANIFEST_FILENAME.equals(name)) {/*如果文件是
               pkg.manifestDigest =ManifestDigest.fromInputStream
               ream(je));
            }
          final Certificate[] localCerts = loadCertificates(jarFi
                                             /*这是整个安全检查的关键，下面我
             …
```

PackageParser通过collectCertificates()来检验程序包中的所有文件是否都符合要求，然后才能返回PackageManager继续执行安装过程。这个函数分为两个部分：

- 解析package包，得到所有文件；
- 对这些文件进行逐一检验。

安全检查的关键在于loadCertificates，如下所示。

```
 /*frameworks/base/core/java/android/content/pm/PackageParser
private Certificate[] loadCertificates(JarFile jarFile, JarEn
   try {
      InputStream is = new BufferedInputStream(jarFile.getInp
      Stream()返回一个JarFileInputStream实例，后者又包含了一个已经被
      Entry实例*/
```

```
        while (is.read(readBuffer, 0, readBuffer.length) != -1)
                       Stream中包含了JarFileInputStream，所以最终是
        }
        is.close();
        return je != null ? je.getCertificates() : null;
    } catch (IOException e) {…
    } catch (RuntimeException e) {…
    }
    return null;
  }
```

整个检验过程主要涉及以下几点。

- CERT.RSA

这是应用程序开发者提供的证书，包含了该开发者的公钥和一系列身份信息。因为是自签名的，就不需要CA的认证。

- CERT.SF

后缀名.SF应该是Signature File的缩写，所以这就是我们所说的签名文件。根据前面学习的密码学基础，它是对“某个文件”的Hash值进行私钥加密产生的。那么针对这里的情况，具体是指哪个文件呢？理论上当然可以对每个文件的摘要分别进行签名，但Android选择了一个聪明点的办法，即它只对整个MANIFEST.MF进行了加密——因为它包含了应用包中所有文件的Hash值。这样既可以检查此文件是否完整可靠，也可以验证程序提供的私钥和公钥是否匹配。

- MANIFEST.MF

只要确认了MANIFEST.MF文件的可靠性，就可以通过读取其中的信息来为APK包中的所有文件做一一校验。接下来的代码中我们侧重于对这一校验过程的分析。

先来看看Read函数的内部实现：

```
    public int read() throws IOException {…
        if (count > 0) {/*如果count大于0，说明还有数据需要写入Veri
                                  initEntry()时已经做过初始化*/
            int r = super.read();
            if (r != -1) {
```

```
                entry.write(r);//写入entry中，为校验做准备
                count--;
            } else {
                count = 0;
            }
            if (count == 0) {
                done = true;
                entry.verify();/*所有数据都已经保存完毕，进入校验阶
            }
            return r;
        } else {
            done = true;
            entry.verify();
            return -1;
        }
    }
```

最后我们再来看看VerifierEntry(在JarVerifier.java文件中)里verify函数的实现：

```
class JarVerifier {…
class VerifierEntry extends OutputStream { //实际上是一个OutputStre
    void verify() {/*这个verify()函数的作用是将CERF.SF解密后的数据
                    以此来证明证书的有效性。因而它并不是用来验证应用程序包
        byte[] d = digest.digest();
        if (!MessageDigest.isEqual(d, Base64.decode(hash))) {/
             MANIFEST.MF中的SHA-1值经过了BASE64编码，因此这里还需要先
           throw invalidDigest(JarFile.MANIFEST_NAME, name, ja
        }
        verifiedEntries.put(name, certificates);
    }
…}
…
```

Android签名机制确保应用程序在安装前没有被恶意篡改，因而有效地保护了开发者的权益。另外，它也为用户选择和安装合法来源的应用程序提供了有力的保障。

20.7　APK重签名实例

前面几个小节我们分析了Android应用程序的签名机制，从中可见整个过程是相对缜密的。但是，这并不代表我们可以“高枕无忧”，无视APK的安全问题了。事实上，由于Android系统是自签名的，我们完全可以对第三方应用程序进行重新签名，然后做二次发布——这样得到的APK通常情况下也可以在Android系统中正常运行。

本小节我们将讲解如何对第三方的应用程序进行重新签名。

- Step1. 解压APK文件

因为APK实际上是一个zip包，所以你可以通过很多常用的工具来把其中的内容解压出来。

- Step2. 删除其中的META-INF文件夹

我们知道，这个文件夹保存了开发者的公钥、签名以及APK中各文件的Hash值等重要信息。重新签名意味着这些资料将被全部更新，因而我们可以删除它们

- Step3. 将上述的文件夹重新打包为zip文件

打包后可以将后缀名由“zip”改为“apk”。我们假设完成这一步操作后的文件名称为“Your Unsigned.apk”

- Step4. 利用jarsigner工具进行重新签名打包

这一步是真正执行重签名的地方，所以尤其关键。

如果你安装的JDK是7或者以上版本，那么建议你通过以下命令行来完成这一任务：

> jarsigner -keystore ~/.android/debug.keystore -storepass android -keypass android sigalg MD5withRSA digestalg SHA1 YourUnsigned.apk androiddebugkey

否则，采用下面的命令：

```
> jarsigner -keystore ~/.android/debug.keystore -storepass android -keypass android YourUnsigned.apk androiddebugkey
```

接着对重签名后的文件进行优化处理：

```
>zipalign 4 YourUnsigned.apk Aligned.apk
```

如果你的操作系统环境是Windows，可以根据实际情况对上述命令行进行微调，但基本上是大同小异的。

如果你觉得命令行的方式太过于繁琐，也可以下载GUI工具来完成。图20-17是目前比较流行的re-sign.jar工具的主界面。

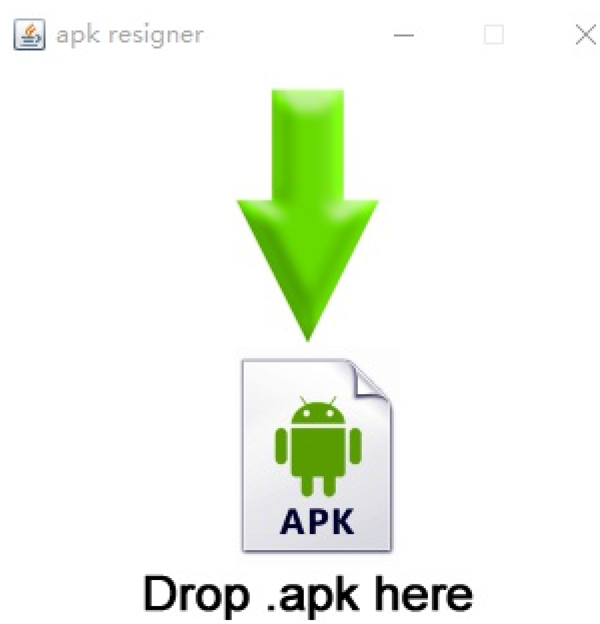

▲图20-17 主界面

可以看到，APK重新签名的过程并不复杂，这或许也是市面上很多Android应用程序被非法二次打包的一大原因。当然，被重新签名的APK的公钥信息与原APK相比显然已经发生了变化。而且公钥和私钥又是配对的，这就意味着在升级应用程序的场景下，我们可以通过比对要安装的APK与老版本APK的公钥信息来判断这个应用程序是否出自同一家开发商，从而在一定程度上来防止恶意程序的破坏。

第21章

Android虚拟机

21.1 Android虚拟机基础知识

21.1.1 Java虚拟机核心概念

如果从1991年James Gosling创立Java的前身——oak算起，Java已经走过了二十多年。其凭借“Write once，Run anywhere”的口号征服了无数的开发者与设备厂商，并仍在不断焕发出新的生机——与其说是Android系统将Java带向了另一个新高度，倒不如说是站在Java这个巨人的肩膀上才造就了Android今天的成绩。

我们知道，Android系统在成立之初就选择Java作为其首选的应用程序编程语言。一方面，当时市面上的Java应用程序已经具备一定的体量，某种程度上有利于Android系统“坐享渔翁之利”；另一方面，Java语言快速构建应用程序的能力对于Google壮大Android生态圈也是大有裨益的。

问题在于，Java程序的运行需要完整的虚拟机环境，而Android系统本身又是一个开源项目，显然无法直接使用商用的JVM（当然，JVM与终端设备之间“水土不服”是另一个重要的考量因素）。怎么办呢？Google给出的答案是自研一整套具有“Android特色”的Java虚拟机运行时环境——不可否认的是，Android虚拟机的诞生过程中，或多或少都会“借鉴”商业JVM中的一些设计思想和技术实现（这同时也为后续Oracle和Google之间的“恩恩怨怨”埋下了伏笔）。

所以虽然严格意义上讲Android系统中的Dalvik/Art并不算100%纯正的Java虚拟机（它们并不完全遵循JVM规范），但“骨子”里看它们和HotSpot等官方JVM又源出一脉。因而建议大家在研究Dalvik/Art之前可以先打好“Java标准虚拟机”这个基础，否则就变成“无源之水”了。

有鉴于此，本小节我们将介绍Java虚拟机的一些核心概念，希望能为大家后续章节的学习打下必要的根基。不过限于篇幅，我们只能对某些关键技术“点到即止”，因而强烈建议读者们可以自行参阅Java和Java虚拟机的相关资料，如Oracle的《Java Language Specificatiodn》《The Java Virtual Machine Specification》等。

如果用一句话来概括Java虚拟机所要解决的核心问题，那么就是它提出的口号，即如何做到“Write once, Run anywhere”。为了达到这一终极目标，它需要把开发人员编写的Java语言文件编译为中间状态的Bytecode，然后再在运行阶段针对具体的平台做“转译”——将字节码翻译成目标平台对应的机器码；其他的诸如JIT、Interpreter、内存分配和回收、线程管理等子系统从本质上说都是为这一终极目标而服务的。

理解上述这点很重要，它将引导我们从更本源的角度来思考JVM的实现。

当我们在分析Java Virtual Machine时，应该注意区分以下几个概念：

- 抽象的Java虚拟机规范；
- 具体的Java虚拟机实现；
- 运行时态的Java虚拟机实例。

第一个概念指的是Oracle官方发布的Java虚拟机协议规范；然后不同厂商可以基于这一规范来实现具体的JVM（如Hotspot）——因而市面上流行的虚拟机实现方案可能会有很多种。并且这些方案并不一定完全采用纯软件来完成，还有可能是软硬件的集合体。

当一个虚拟机程序运行起来后，便形成了Java虚拟机实例。按照Java虚拟机规范中的描述，我们可以从Subsystem、Memory Area、Data Type和Instruction几个维度来度量JVM。

毋庸置疑，JVM的首要任务就是执行Java程序，因而通常情况下一个虚拟机实例与程序的生命周期是紧密绑定在一起的。JVM中的线程可以分为daemon和non-daemon两种，前者是指VM自身使用的线程，如执行垃圾回收操作的工作线程（程序也可以将它的线程标注为daemon thread）。

虚拟机是和物理机相对应的概念，通常而言，一个虚拟机就是对某种物理形态的模拟。我们知道，计算机执行代码的过程实际上也代表了其自身状态的迁移过程——这个观念从图灵机伊始，本质上是“亘古未变”的。抽象来讲，计算机处理代码的逻辑如下所示：

```
while(true)
{
    根据当前pc寄存器取出指令;
    执行指令;
    调整pc寄存器值;
}
```

虚拟机和物理机的处理逻辑可以说是“一脉相承”的，只不过它们各自所面临的具体对象和场景都有所差异。

读者可以思考一下，如果以一个简单模型来描述Java虚拟机，应该是什么样子的呢？相较于通用型的虚拟机（如Qemu），JVM的目的性更为明确，即“根据输入的代码，得到正确的结果”，如图21-1所示。

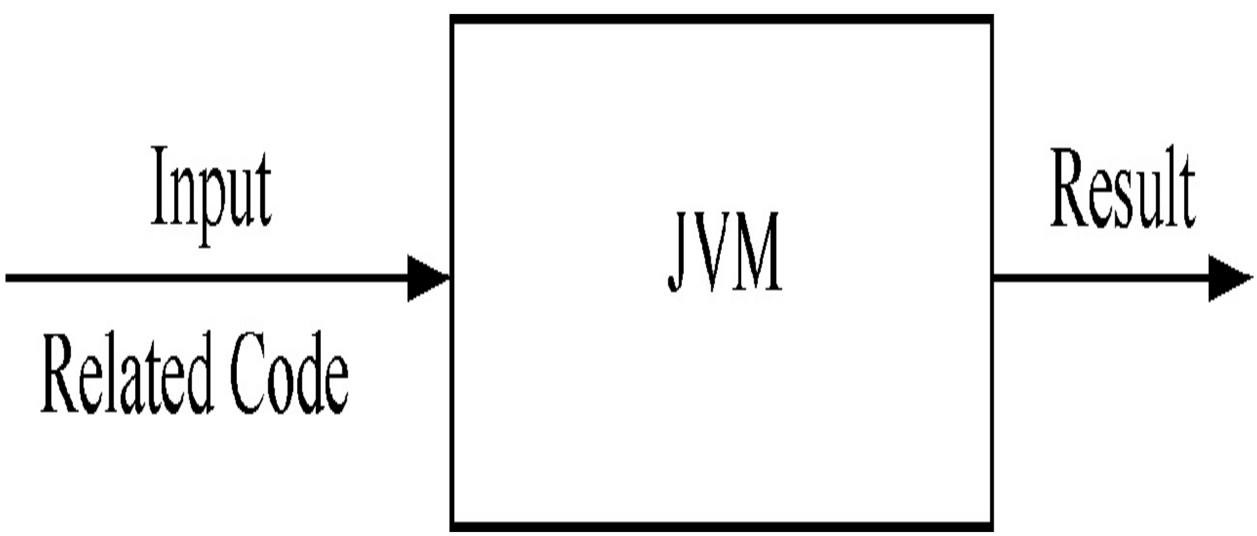

▲图21-1　JVM的0层模型

图21-1中我们并没有将Input部分直接限定为Java Code，这是因为随着JVM的不断发展，它已经不再拘泥于最初的范畴了。比如我们完全可以在编译阶段就把Java代码编译成机器码，这种情况下在JVM中执行的就不是Java Code了。

JVM的内部运作机制是相当复杂的。根据《The Java Virtual Machine Specification》中的描述，Java虚拟机在运行时的逻辑结构大致如图21-2所示。

接下来我们逐一分析JVM架构中的部分核心模块，以此为基础来“窥探”和理解它的内部运行机制。

（1）ClassLoader和双亲委派模型

ClassLoader（类加载器）提供了一种灵活的方式，来帮助应用程序将字节码流以自定义的方式加载到虚拟机中。它既是Java虚拟机中的一个重要特性，同时也是OSGI、热部署等技术的基础。

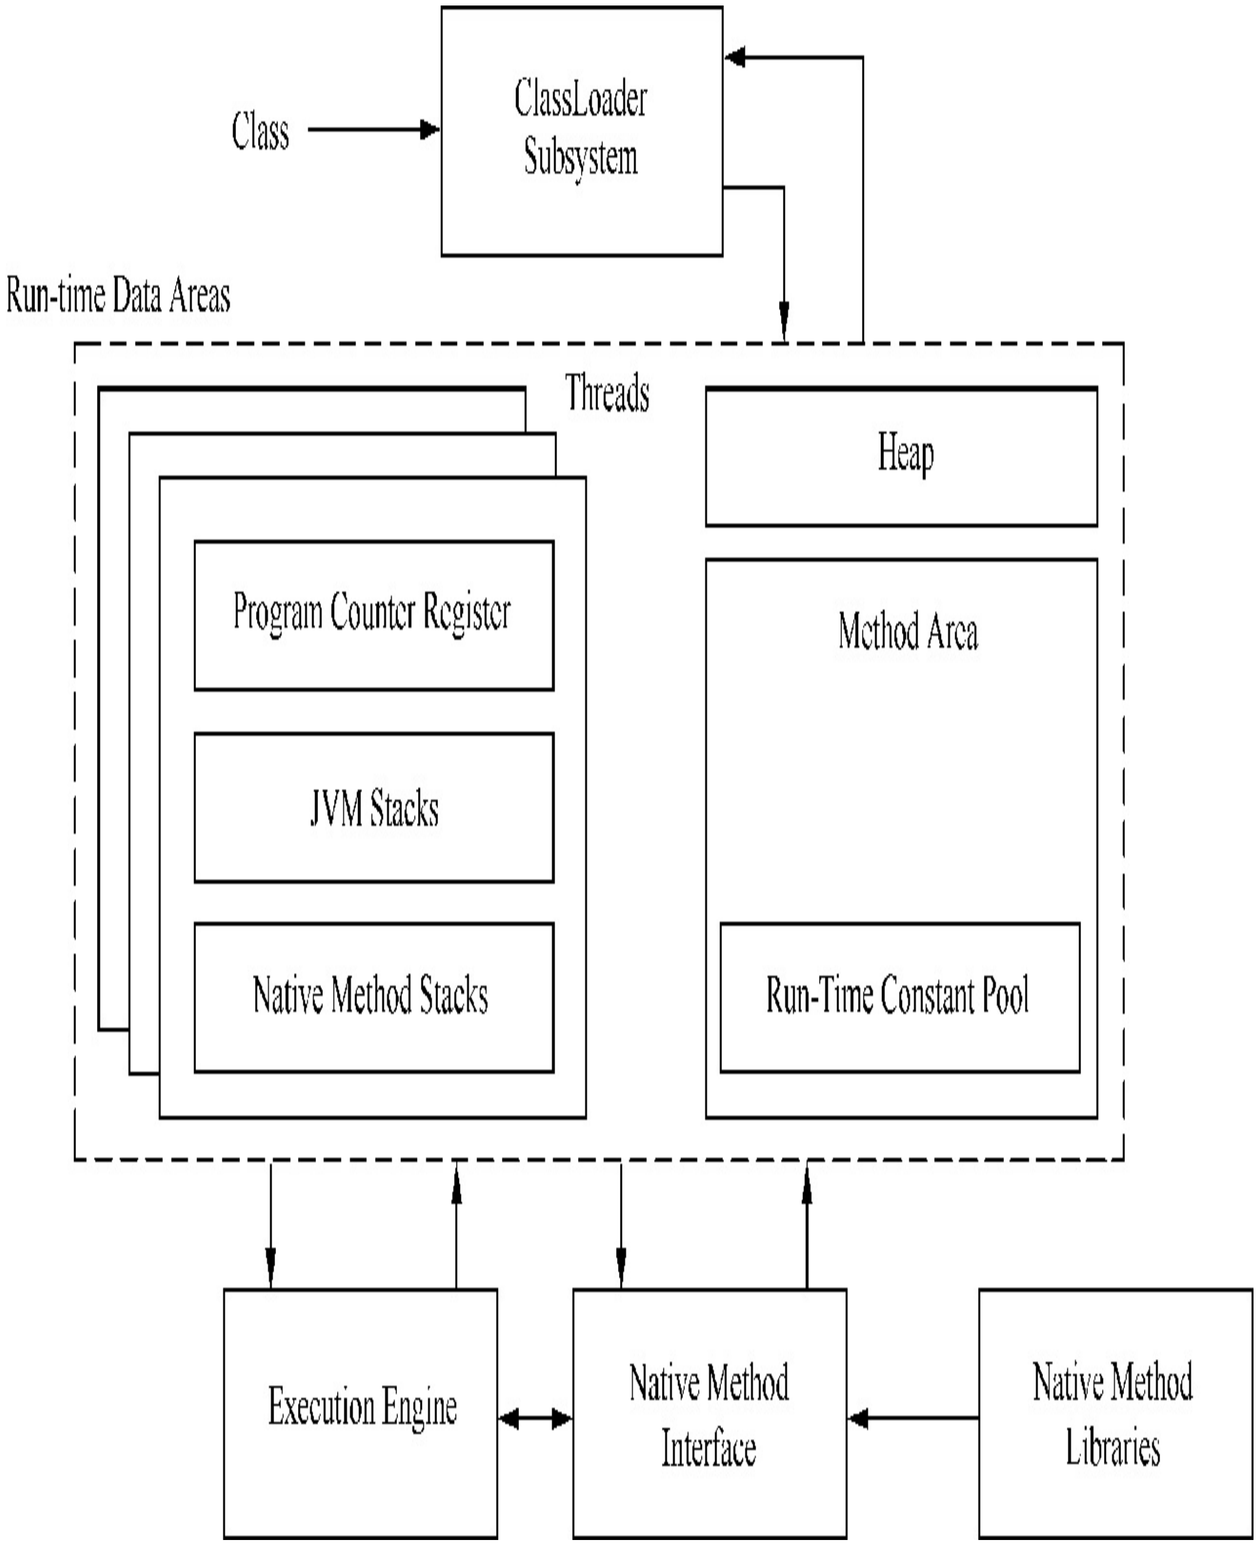

▲图21-2 Java虚拟机运行时

Java虚拟机中通常会存在如下几种ClassLoader类型：

- Bootstrap ClassLoader；
- Extension ClassLoader；
- System ClassLoader；
- User ClassLoader。

ClassLoader用于加载Java类，而大多数类型的ClassLoader自身却也是Java类，这就意味着我们需要一个非Java的“鸡”来生第一只“蛋”——这就是Bootstrap ClassLoader，从它的名称“Bootstrap”也同样可以看出这一点。Bootstrap ClassLoader由C/C++语言编写完成，是虚拟机自身管理功能的一部分。它所加载的类通常位于[JAVA_HOME]/lib中，或者由-Xbootclasspath指定，属于Java的核心实现部分（例如java.*、javax.*等）。

Extension ClassLoader则负责JRE扩展目录中的各种类的加载，例如[JAVA_HOME]/lib/ext文件夹中的内容如图21-3所示。

System ClassLoader又被称为应用程序类加载器，它用于加载CLASSPATH中的各种类对象，可以通过ClassLoader.getSystemClassLoader()来获取。如果应用程序没有提供自定义的ClassLoader，那么默认情况下系统将使用System ClassLoader来加载应用程序中的类。

最后一种类加载器由应用程序提供，它们都应该继承自java.lang.ClassLoader，并按照规范实现其中的接口。

那么面对这么多的类加载器，Java虚拟机应该如何管理，它们之间又有什么关联呢？

根据Java Specification中的规定，任何一个类都必须由ClassLoader和类名称两者结合才可以得到唯一确定。换句话说，通过两个ClassLoader加载同一个Class文件，最终生成的两个对象之间是没有直接联系的。

为了避免由此产生的类关系混乱，Java设计出了“双亲委派”模型，它的核心框架描述如图21-4所示。

用户自定义的ClassLoader（即最底层的实现）首先在Cache中查询被加载对象是否已经存在。如果答案是肯定的话，直接返回结果；否则

它会优先委派它的上一级（即System ClassLoader）去执行加载动作，而不是马上由其自身来尝试加载目标对象。System ClassLoader也遵循同样的处理逻辑，直到模型到达最顶端——Bootstrap ClassLoader。这样一来程序中的基础类（如Object）都处于同一空间域中，从而有效避免了混乱的发生。

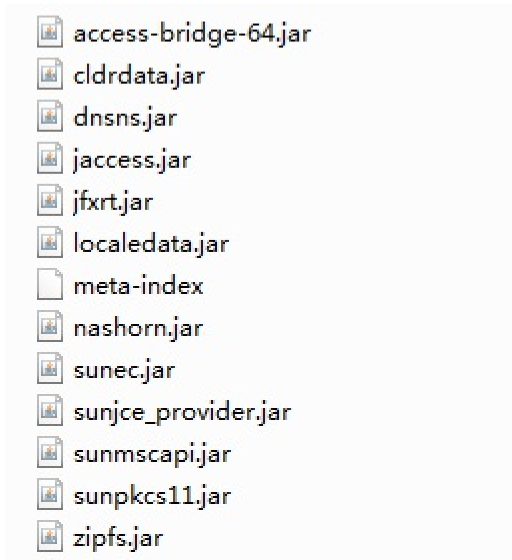

▲图21-3　文件夹

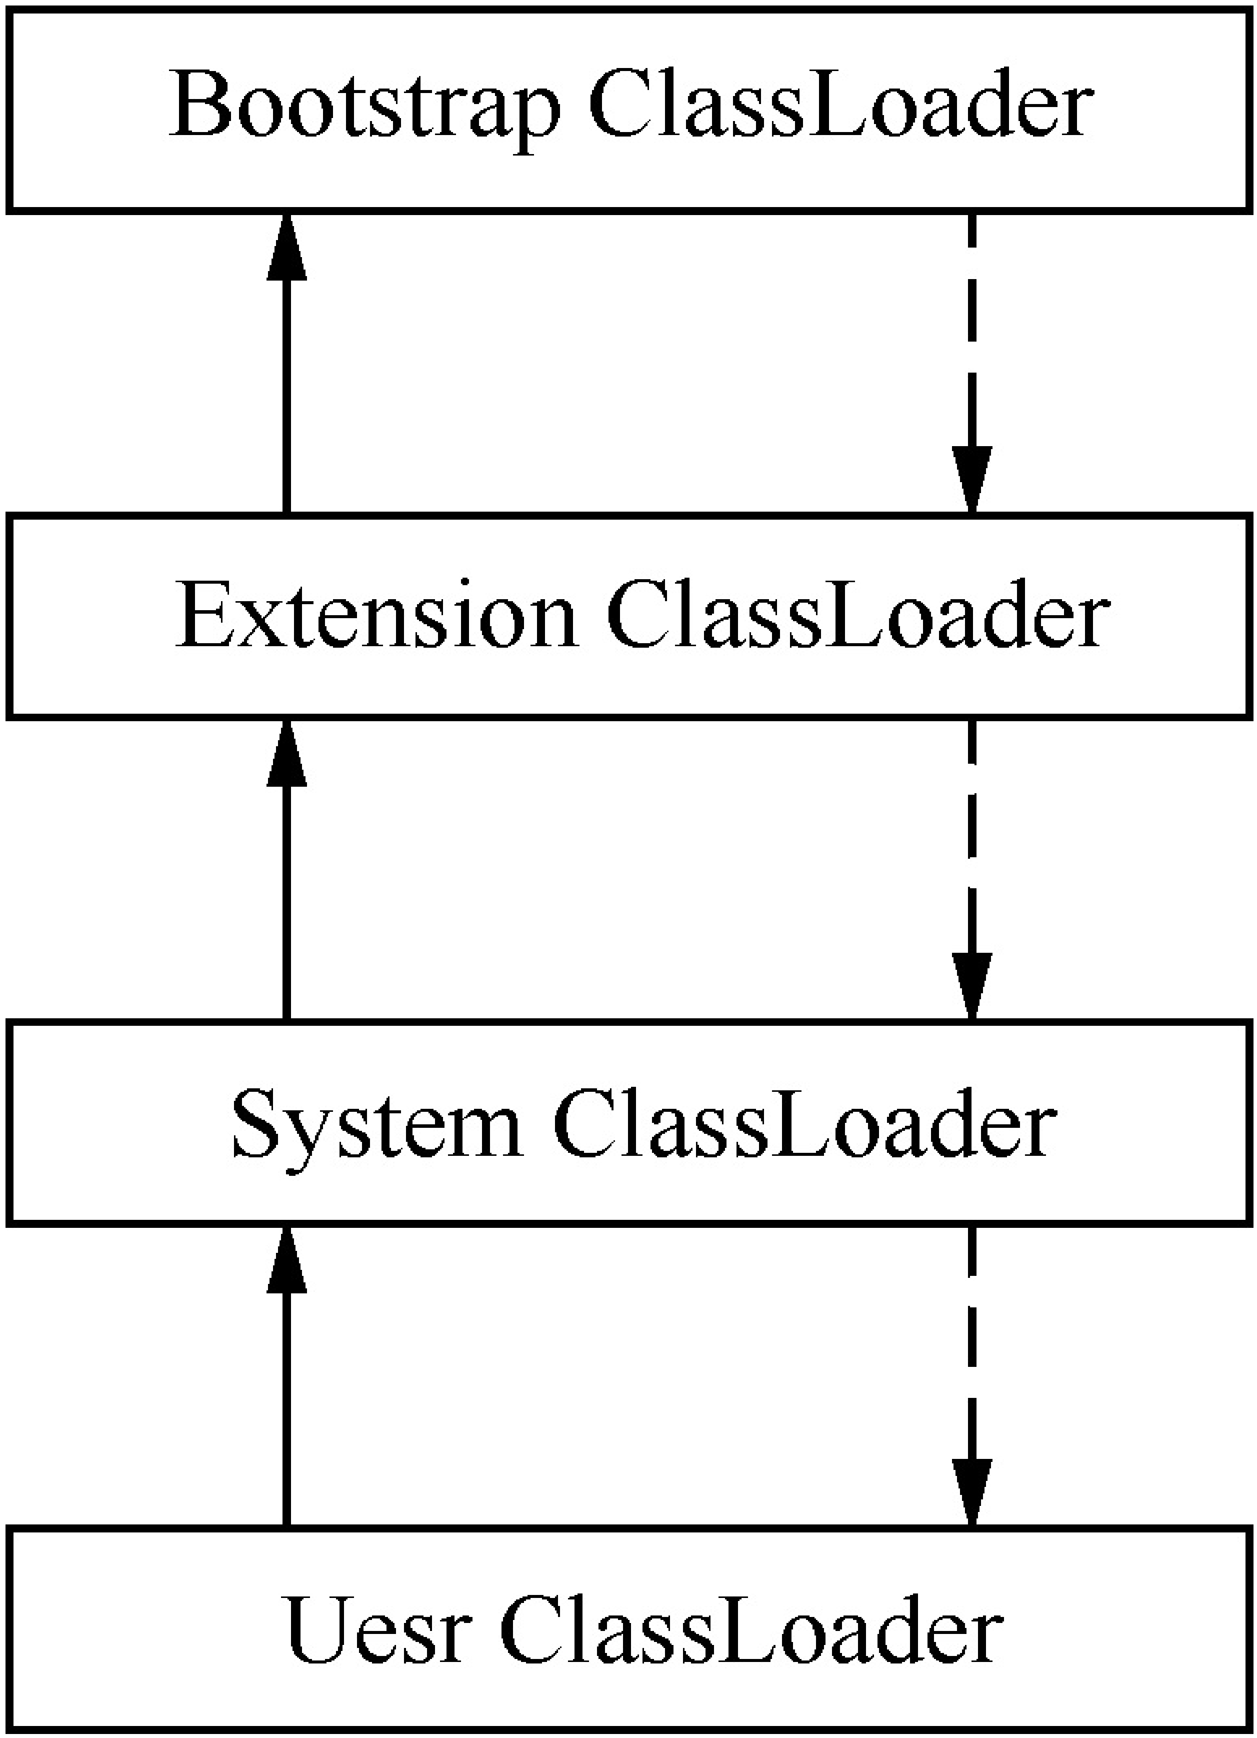
Bootstrap ClassLoader
Extension ClassLoader
System ClassLoader
Uesr ClassLoader

▲图21-4　Java双亲委派模型

下面我们结合Android系统中的ClassLoader. loadClass()，来验证一下实际的类加载过程：

```
/*libcore/ojluni/src/main/java/java/lang/ClassLoader.java*/
protected Class<?> loadClass(String name, boolean resolve)
        throws ClassNotFoundException
    {
            // First, check if the class has already been loaded
            Class c = findLoadedClass(name);//Cache中是否已经存在目标
            if (c == null) {//之前未加载过目标类
                long t0 = System.nanoTime();
                try {
                    if (parent != null) {//优先让parent执行加载操作
                        c = parent.loadClass(name, false);
                    } else {
                        c = findBootstrapClassOrNull(name);
                    }
                } catch (ClassNotFoundException e) {
                    // ClassNotFoundException thrown if class not
                    // from the non-null parent class loader
                }

                if (c == null) {//双亲模型中的所有上层都没有加载成功，现
                    long t1 = System.nanoTime();
                    c = findClass(name);
                }
            }
            return c;
    }
```

这段代码的处理逻辑并不复杂，如下所示。

Step1. 首先检查是否已经加载过目标对象，即findLoadedClass()。

Step2. 如果上一步中未找到目标类，那么接下来优先调用它的父加载器提供的loadClass。假如没有父加载器的话，则使用内建（built-in）的ClassLoader。

Step3. 如果仍然没有加载成功，此时就可以启动自身的加载器功能了，即findClass()。

值得一提的是，ClassLoader并非只要完成类的加载操作就可以“万事大吉”了，它的完整职责和对应的处理流程如下所示。

Step1. Loading

查找和加载目标类数据。

Step2. Linking

链接过程是检验目标类是否合法有效的关键环节。它又可以被细分为以下几个子项：

- Verification

检验加载的数据是否合法、正确

- Preparation

为类变量和其他数据分配合理的内存空间，并初始化为默认值。

- Resolution

将符号型引用转换为直接引用（类似于C/C++中的重定位过程）的过程。

Resolution（解析）过程的输入端是符号引用，输出端则是直接引用。我们可以这么理解，符号引用虽然是和具体的内存布局无关的，但是必须遵循统一的标准以便可以在不同的硬件平台上被正确运行；直接引用则是能指向目标对象的内存地址、偏移量，或者其他可以代表目标实例的对象。

Step3. Initialization

为上述步骤中的对象做初始化操作。

只有执行了如上几个步骤后，类对象才算是真正地加载完成了。

（2）Runtime Data Areas

Runtime Data Areas是JVM在程序运行过程中所需的数据区域，由Stack、Heap、MethodArea等多个部分组成。

其中Program Counter Register区是实现Java多线程管理的关键之一（从前面的框架图中不难发现，每个Java虚拟机线程都需要彼此独立的PC寄存器）。如果被执行的函数属于native方法的话（需要特别注意的是，虽然C/C++在JNI中使用得最为广泛，但Java虚拟机规范中并没有特别规定native语言具体是什么），那么这个PC寄存器实际上是没有定义的（因为native函数代码可以被物理硬件直接识别并执行，此时并不需要模拟的PC Register）。

JVM中的Stack区域也是线程独立的，它们伴随新线程的创建而出现，并随线程结束而消亡。Java虚拟机中的栈和其他编程语言中的作用是类似的，即用于存储本地变量和栈帧等临时数据。什么叫栈帧呢？

Java规范中对Stack Frame的定义如下所示：

“A frame is used to store data and partial results, as well as to perform dynamic

linking, return values for methods, and dispatch exceptions”

可见栈帧和函数之间是一对一的关系，它的内部包含了本地变量数组、操作数栈以及对运行时常量池的引用等多重信息。

当JVM执行一个新函数前，首先需要创建并初始化一个Stack Frame，然后压入栈中。由此可见Stack中的frame数量将随着被调用函数数量的增加而不断上升——除非函数执行结束，此时JVM才会释放其对应的frame。Stack Frame是解释器中非常重要的组成元素，建议大家可以结合起来理解。

JVM中另一个重要的运行时内存区域是Heap。它通常被用于给各种类实例和数组分配动态内存，而且这一部分内存空间是由所有JVM线程共享的。我们所说的内存管理和垃圾回收机制大多情况下也是专门针对堆内存开展的，后续小节中对此还会有进一步的描述。

和Heap一样作为所有线程共享区域而存在的还有Method Area。顾

名思义，这个区域保存的内容有点类似于操作系统进程中的“Text”Segment，即俗称的“代码段”。它包含了每个Class结构中的运行时常量池、方法数据、方法的源代码等一系列重要信息。

Native Method Stacks简单来讲用于支撑JVM运行native语言（譬如C/C++语言）编写的代码。不过这块区域并不是必需的，取决于JVM的能力以及程序的具体需求。下面是一个Java的运行时范例，如图21-5所示。

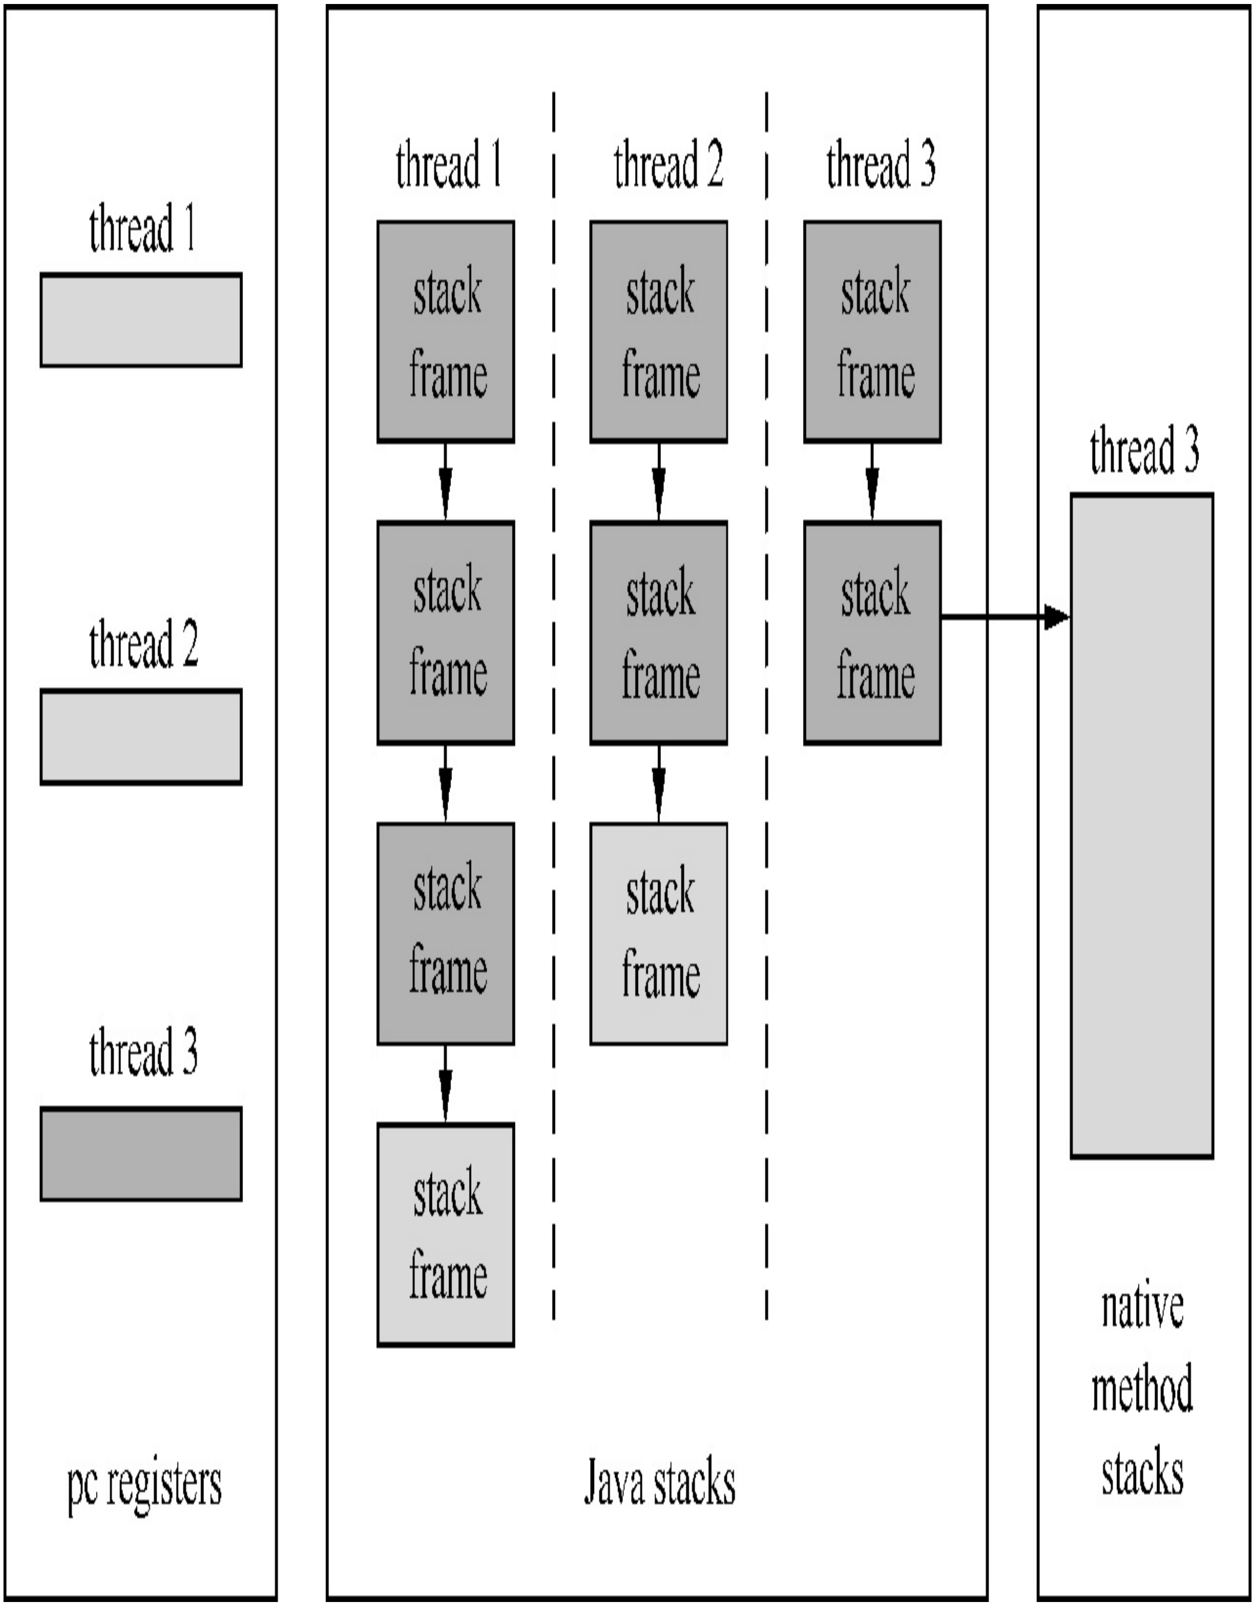

▲图21-5　Java运行范例 （引用自《Inside the Java Virtual Machine》）

从图21-5中可以看到，这个Java程序当前有3个线程，其中线程1和2正在执行Java Method，因而PC Register指向的是正在执行的语句（浅色块）；而线程3因为正在执行Native Method，所以它的PC寄存器是没有定义的（暗色块），同时native method stack被用于支撑thread 3执行本地代码。

（3）堆和垃圾回收

前面我们说过，堆内存的一个特点是“进程独立，线程共享”。换句话说，每个JVM实例都拥有它们自己的Heap空间，从而保证了程序间的安全性；不过进程内部的各个线程则会共享一个堆空间，因而需要注意访问堆变量时的代码同步问题。

Java相较于C/C++语言的一个重要区别是它具备垃圾自动回收的能力——这同时也是堆内存管理系统最关键的一个功能点。随着JVM的不断更新换代，其所支持的垃圾回收算法也在不停地推陈出新。我们这里简单讲述一下业界目前最为流行的回收算法之一，即“分代垃圾回收”算法，如图21-6所示。

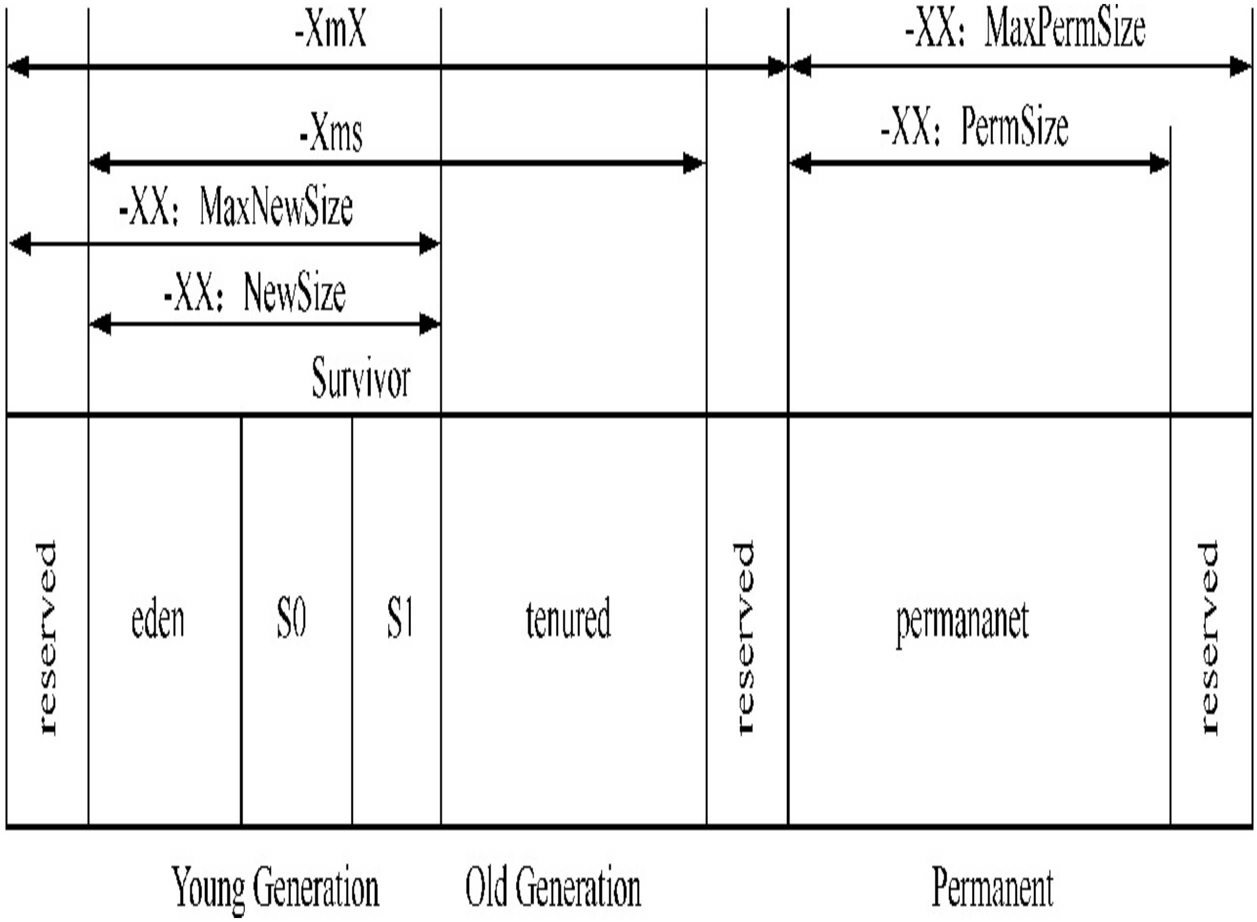

▲图21-6　内存分代管理简图

简单而言，分代回收机制会将内存划分为如下“三代”来区别管理：

- Yong Generation

即年轻代内存，又可以被细分为eden、s0和s1三种，其中后两者也被称为“from space”和“to space”。

- Old Generation

老年代内存又被称为“Tenured Space”。

- Permanent Generation

永久代内存，用于存储和类、方法相关的Meta Data，并不属于

Heap的范畴，在某些情况下可以不予以考虑。

JVM对不同代中的内存所采用的垃圾回收算法也是有区别的。大致流程是：

所有内存空间的申请请求都首先考虑从Eden区分配。此时分为两种情况：如果能顺利满足该内存申请则“皆大欢喜”；否则会触发一次Minor GC，清理Eden以及其中一个Survivor中的垃圾。JVM规定Survivor至少得有一个始终是空的——并被标记为“To Survivor”。清理完成后，那些无法回收的对象（包括Eden和Survivor）会被转移到另一个Survivor中。此时因为两个Survivor的职责发生了变化，所以它们会互换各自的标记（即From和To）。

那么对象什么时候会被复制到Old Space中呢？这取决于下面两种情况：

- Case1: Survivor已满

那么它所管理的对象就会被复制到Old Space中。

- Case2: 对象的存活时间达到一定阈值

阈值可以通过MaxTenuringThreshold来调整。每执行一次MinorGC就代表存活对象“又长了一岁”，直到它们超过阈值达到“质变”后被复制到Old Space中。

如果Old Space也满了，就会触发一次Full GC，对内存垃圾进行全面清理。假设经过Full GC仍无法满足程序的内存请求，那么就很可能产生OutOfMemory的错误。

当然，上述流程只是内存分代管理和回收的核心思想，实际的内部实现远比我们描述得复杂，感兴趣的读者可以参考Java官方文档获取更多信息。

（4）Execution Engine

执行引擎是虚拟机中的中枢系统，它将为程序的运行提供源源不断的血液供应。目前主流的虚拟机一般都支持多种执行方式，例如：

- Java字节码解释执行；
- 在运行阶段根据一定的算法将使用频率高的字节码编译成Native Code（JIT），然后再执行；
- 在编译阶段就将字节码直接转换成机器码，类似于Art虚拟机所采用的AOT技术。

一个方法的字节码流是由一连串指令序列构成的。每条指令都包含了一个单字节的opcode，以及紧随其后的0个或多个操作数（理论上JVM是零操作数的，但事实上会有一些例外情况）。执行引擎在同一时间只能运行一条指令。它首先获取指令的opcode，以及对应的操作数（如果有的话），然后执行它们——如此循环往复直到线程正常或异常结束。如果程序请求执行一个Native Method，那么执行引擎在完成这一请求后还是会返回到字节码流中继续执行。

接下来我们将通过一个实际范例来对比基于栈和基于寄存器的执行引擎的实现差异，从中大家也可以学习到Execution Engine处理字节码的典型过程。

（5）基于寄存器和基于栈的Java虚拟机实现

Java虚拟机执行字节码有很多种实现方式，其中运用最广泛的就是基于寄存器和基于栈两种。关于它们二者之间的“优劣”之争，业界讨论由来已久（比较经典的是一篇名为《Virtual Machine Showdown: Stack Versus Registers》的论文，有兴趣的读者可以自行查找阅读）——简单而言，这两种技术各有千秋，不能一概而论。开发商应该根据具体需求因地制宜地选择最适合自己的实现方式。

当然，一个不争的事实是：目前市面上大多数的JVM都是基于栈实现的；这与真实世界中的物理处理器正好相反，因为后者是基于寄存器的。“存在即是合理”，我们不难推断出在虚拟机领域，基于栈的“模拟”方式一定有其过人之处。譬如：

- 单条指令更为紧凑

由于JVM中执行的是字节码，不需要像基于寄存器的架构那样显性地指定源和目标，因而采用栈实现的方式可以降低单条指令的Code Size。

- 可移植性更强

基于寄存器的虚拟机需要考虑很多与目标平台强相关的因素。比如我们需要根据硬件平台的真实寄存器的数量、它们的用途等，来实现虚拟机中的寄存器和真实世界中的寄存器之间的“映射关系”，从而提高执行效率。相较而言，栈虚拟机没有这方面的顾虑，因而通用性更强。

当然，基于栈的实现方式也有其缺点，例如：

- 由于指令是基于栈来操作的，导致了完成同一个任务所需的指令数比基于寄存器的架构要多。
- 从执行速度来看，基于寄存器的架构具有一定优势。因为基于栈的实现方式需要更多次数的内存读写操作，而且完成同一个操作所需的指令数量也比前者要多（虽然单条指令的体积要小）。

为了让大家对这两种技术的内部实现有一个更直观的认识，我们特别编写了一个Java小程序，并在接下来的内容中加以详细剖析。

其中Java源码摘抄如下：

```
public class Calculator {
      public static void main(String args[]){
          Calculator cal = new Calculator();
          System.out.println("add="+cal.add());
      }

      public int add()
      {
          int a=400;
          int b=200;
          int c= a+b;
          return c;
      }
}
```

首先，我们将上述代码段对应的程序在Host机上进行编译，并使用以下命令来分析对应的字节码：

```
javap –c XX.class
```

得到的结果如下：

```
public class calc.Calculator {
```

```
  public calc.Calculator();
   Code:
      0: aload_0
      1: invokespecial #8              // Method java/lang/Object
      4: return

  public static void main(java.lang.String[]);
   Code:
      0: new           #1                  // class calc/Calculat
      3: dup
      4: invokespecial #16                 // Method "<init>":()V
      7: astore_1
      8: getstatic     #17       // Field java/lang/System.out:Lj
     11: new           #23       // class java/lang/StringBuilder
     14: dup
     15: ldc           #25                 // String add=
     17: invokespecial #27  // Method java/lang/StringBuilder."<i
     20: aload_1
     21: invokevirtual #30  // Method add:()I
     24: invokevirtual #34  //Method java/lang/StringBuilder.appe
     27: invokevirtual #38  // Method java/lang/StringBuilder.toS
     30: invokevirtual #42  // Method java/io/PrintStream.println
      33: return

  public int add();
   Code:
      0: sipush        400
      3: istore_1
      4: sipush        200
      7: istore_2
      8: iload_1
      9: iload_2
     10: iadd
     11: istore_3
     12: iload_3
     13: ireturn
}
```

以add()函数为例，我们看到其中包含了很多诸如sipush、istore_x这样的栈操作指令，不难理解这是针对“栈实现虚拟机”而生成的编译结果。

下面我们再以图例的形式来帮助大家理解这些指令，如图21-7所示。

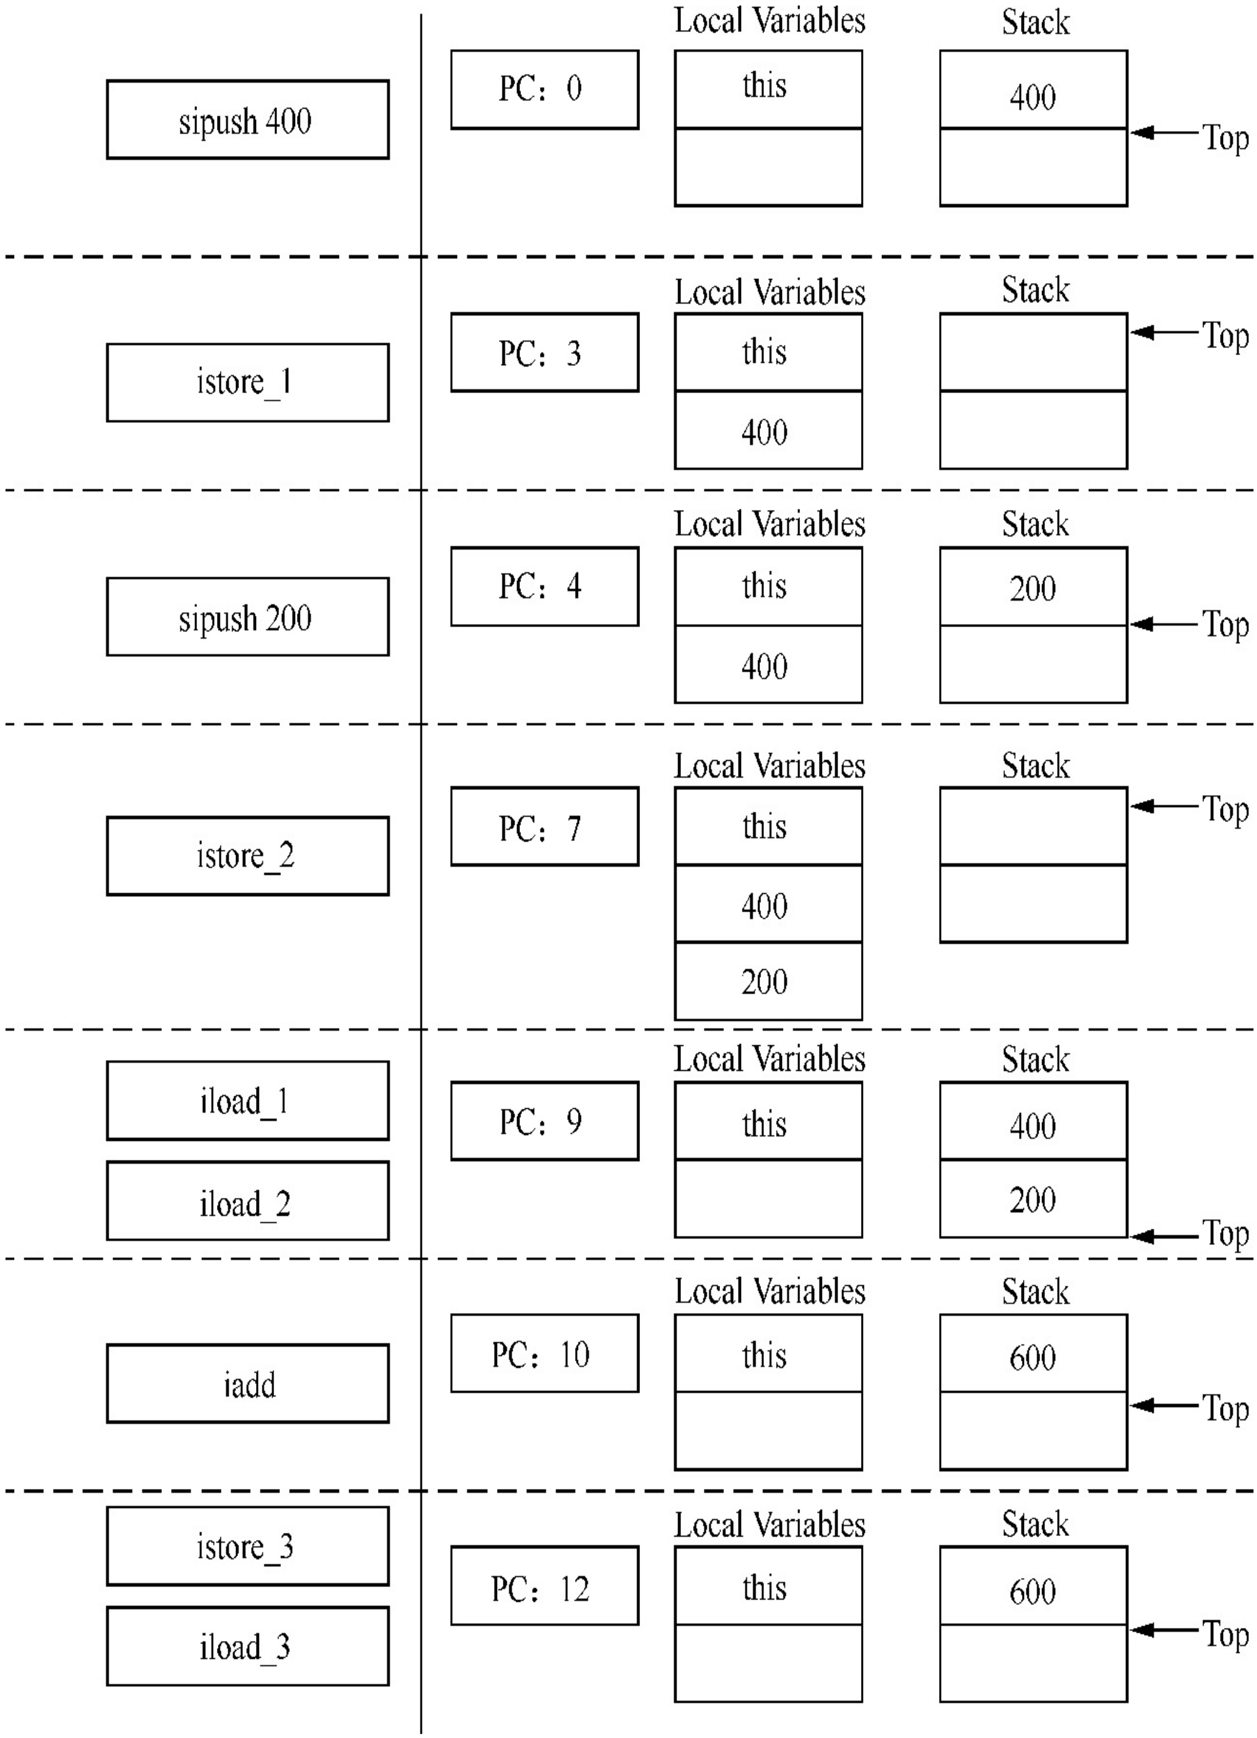

sipush 400
PC: 0
Local Variables
this
Stack
400
Top
istore_1
PC: 3
Local Variables
this
400
Stack
Top
sipush 200
PC: 4
Local Variables
this
400
Stack
200
Top
istore_2
PC: 7
Local Variables
this
400
200
Stack
Top
iload_1
iload_2
PC: 9
Local Variables
this
Stack
400
200
Top
iadd
PC: 10
Local Variables
this
Stack
600
Top
istore_3
iload_3
PC: 12
Local Variables
this
Stack
600
Top

▲图21-7　指令

图例中的左半部分代表的是当前正在执行的指令，右边则是“栈”中的最新状态。由于篇幅有限，我们合并了某些相似指令的执行过程（例如iload_XX）。

通过前面的学习，我们知道Stack Frame中包含了本地变量区、操作数栈等信息，基于栈的虚拟机事实上就是借助于对这些存储区域的“腾挪”来执行函数功能的。

这个例子相对简单，但“麻雀虽小，五脏俱全”，相信大家结合上述图例已经学习到了基于栈的虚拟机的基本原理了。接下来我们就可以切入到基于寄存器的实现方式了——被分析对象仍采用上述的add函数，只不过这次我们将它编译成Android版本，结果如下：

```
00042c:                                      |[00042c] com.example.myapp
00043c: 1300 9001                            |0000: const/16 v0, #int 40
000440: 1301 c800                            |0002: const/16 v1, #int 20
000444: 9002 0001                            |0004: add-int v2, v0, v1
000448: 0f02                                 |0006: return v2
```

通过对比基于栈和基于寄存器的编译结果，我们不难发现，基于寄存器的方式所产生的指令数量相对较少；但每一条指令所占的空间却比基于栈的方式要多（譬如00043c和000444这两条都是4字节的指令；000448则是一条2字节指令）。

另外，基于寄存器的编译指令和我们常见的汇编代码是非常相似的。在我们这个范例场景中，函数add()的处理逻辑比较简单，所以只用到了v0、v1和v2共3个寄存器。指令序列利用这3个寄存器计算出400+200的“和”，并将最终结果通过v2来返回给调用者。

相信从这个范例中，大家可以学习到基于栈和基于寄存器的执行引擎在代码长度、指令数量和执行方式等多方面的区别。

21.1.2　LLVM编译器框架

LLVM的全称是Low Level Virtual Machine，最初诞生于University of Illinois at Urbana-Champaign，是一个开源项目。根

据其官方网站上的表述，Virtual Machine这个名字起得并不是特别贴切，因为LLVM和我们传统意义上的虚拟机没有太大关系——它本质上表达的是："The LLVM Project is a collection of modular and reusable compiler and toolchain technologies"。换句话说，相对于传统的编译器，LLVM的价值在于它的"可模块化"以及"可重复使用"。

随着LLVM的不断发展状大，它所提供的Toolchain数量也在增长。目前LLVM包含的核心子项目如表21-1所示。

表21-1　LLVM各核心子项目释义

Sub-Projects	Description
LLVM Core libraries	提供了与具体的编译源和编译目标无关的优化器，以及支持多种主流CPU的代码生成工具
Clang	C/C++/Objective-C编译器
Dragonegg	这个子项目实现了LLVM优化器/代码生成器
LLDB	Native Debugger
libc++和libc++ ABI	实现了标准的C++库，并完全支持C++11规范
Vmkit	基于LLVM技术实现的Java和.NET虚拟机（不过当前已经停止维护）

libclc	实现了标准的OpenCL库
SAFECode	为C/C++程序提供了内存安全的编译器
lld	这是clang/llvm内置的linker

学习LLVM最好的资料还是llvm.org官网，以及它的原始作者Chris Lattner（这位出生于1978年的年轻人之前或许并不为大多数读者所熟知。但随着他加入Apple公司，以及其主导的Swift语言的日益流行，这位LLVM的主要缔造者收获了越来越多的掌声）所写的一篇文章，大家可以从下面链接中找到：

http://www.aosabook.org/en/llvm.html

LLVM的核心思想并不复杂，如图21-8所示。

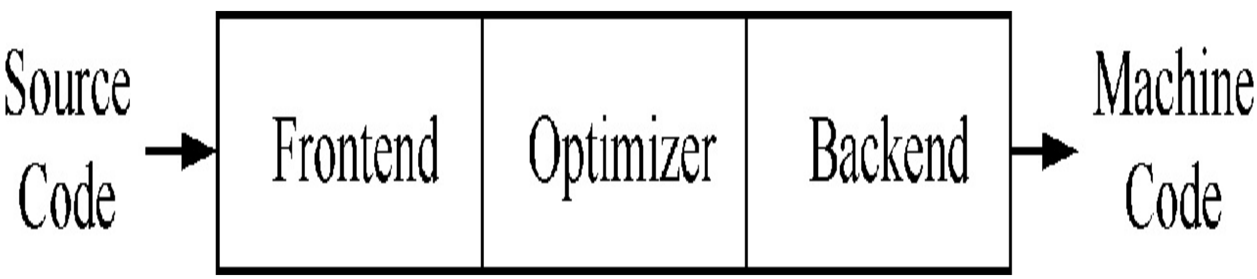

▲图21-8 Three-Phase Compiler （引自http://www.aosabook.org/en/llvm.html）

这就是LLVM的抽象框架，看上去相当的简洁。主要分为3个部分。

- Frontend

前端负责分析源代码、检查错误，然后将源码编译成抽象语法树（Abstract Syntax Tree）。

- Optimizer

优化器如其名所示，会通过多种优化手段来提高代码的运行效率，而且它在一定程度上是独立于具体的语言和目标平台的。

- Backend
- 后端也被称为是代码生成器，用于将前述的源码转化为目标平台的指令集。

LLVM的模块化和可重复使用的设计理念使得旨在支持多种源码语言和目标平台的编译器受益良多。

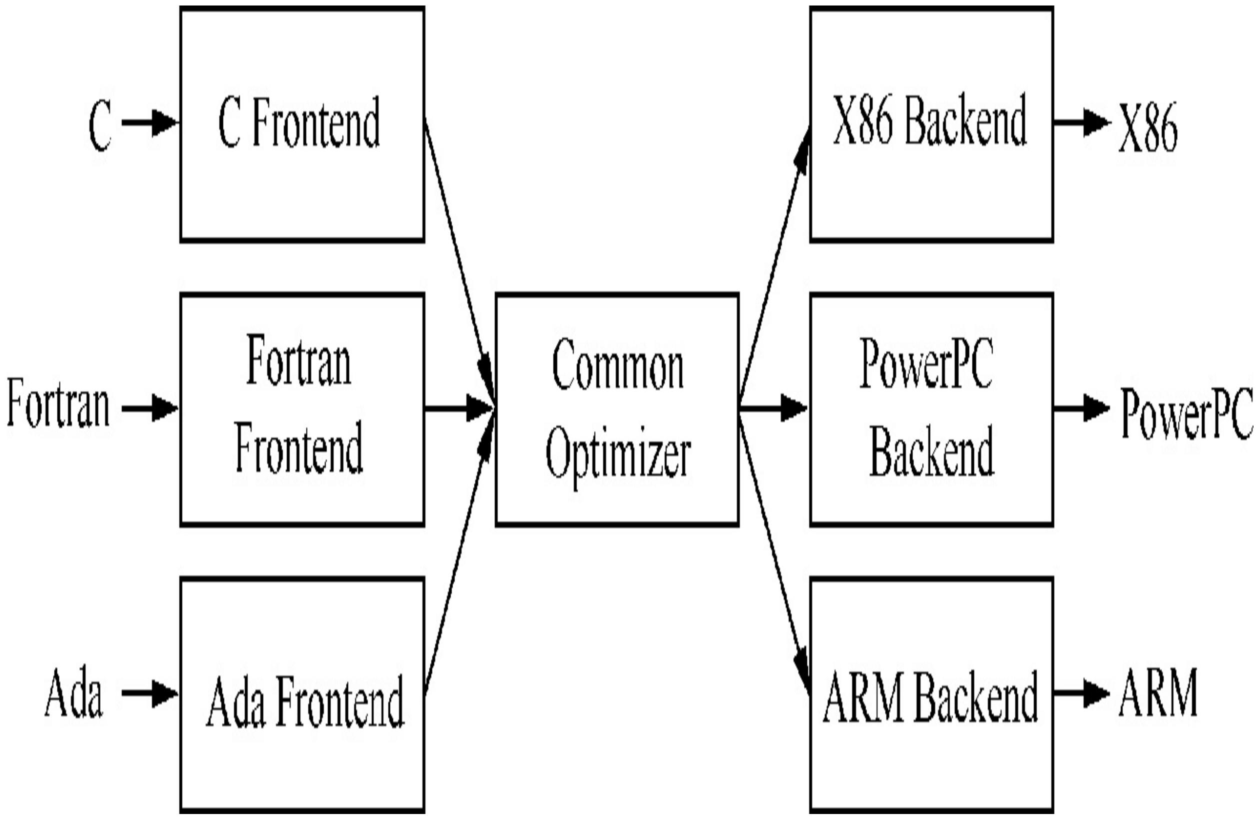

▲图21-9　LLVM的模块化（引自http://www.aosabook.org/en/llvm.html）

从图21-9中我们不难看出，如果要让基于LLVM框架的编译器支持一种新语言，那么所要做的可能仅仅是实现一个新的Frontend，而已有的Optimizer和Backend则能做到重复使用。这无疑是对传统编译器的一大创新，同时大大降低了开发周期和开发难度。

LLVM的上述能力得到实现的前提，在于它的一个非常重要的设计——Intermediate Representation（简称IR）。IR能在LLVM的编译器中（具体而言是在Optimizer阶段）以一种相对独立的方式来表述各种源代码，从而很好地剥离了各种不同语言间的差异，进而实现模块的重用。下面我们引用官方的一个范例来让大家对IR有个直观的认识。

范例是使用C语言编写的两个简单函数：

```
unsigned add1(unsigned a, unsigned b) {
  return a+b;
}

// Perhaps not the most efficient way to add two numbers.
```

```
unsigned add2(unsigned a, unsigned b) {
  if (a == 0) return b;
  return add2(a-1, b+1);
}
```

这两个add函数完成了相同的功能，即计算两个变量之和，只不过在实现上略有差异——而且从执行效率上看add1相对于add2更可取些。

在LLVM编译器中它们首先会被转化成IR，对应的.ll文件如下所示：

```
define i32 @add1(i32 %a, i32 %b) {
entry:
  %tmp1 = add i32 %a, %b
  ret i32 %tmp1
}

define i32 @add2(i32 %a, i32 %b) {
entry:
  %tmp1 = icmp eq i32 %a, 0
  br i1 %tmp1, label %done, label %recurse

recurse:
  %tmp2 = sub i32 %a, 1
  %tmp3 = add i32 %b, 1
  %tmp4 = call i32 @add2(i32 %tmp2, i32 %tmp3)
  ret i32 %tmp4

done:
  ret i32 %b
}
```

从上述add函数的IR描述中，可以看到它既有点类似于某种低级的RISC指令集，同时又在尽力和具体的机器语言“保持距离”——后面这点尤为重要，它是LLVM能够轻松支持多种语言和目标平台的关键所在。可想而知，IR这个“中间人”的职责就是保证前端和后端的“无缝”对接——这意味着，IR既不能太复杂，否则前端所生成的IR很可能会变得异常繁琐；同时也不能太“简单”，否则也无法保证优化工作的正常开展。

关于IR的更多细节（例如怎么书写一个IR的优化器，IR与前端源码具体是如何转化的等等）及内部实现原理，强烈建议大家能够自行查阅相关资料并做更深入的分析学习。

21.1.3 Android中的经典垃圾回收算法

Garbage Collection（垃圾回收）简单来讲是一种自动化的内存管理机制。它的历史可以追溯到上世纪的50年代，所以并非Java语言的专利。但不可否认的是，Java语言的蓬勃发展极大地推动了GC技术的推陈出新，进而让其为更多的开发者所知晓。我们曾在本书基本知识章节谈到过内存指针的强大之处，以及它可能带来的各种梦魇，也分析了Google为了应对这一问题所引入的智能指针机制。可见无论是“先天”还是“后天”，“自动化内存管理”这一优良特性都受到了各种语言的青睐。当然，凡事通常有利也有弊——自动化内存管理带来的直接影响是系统资源的额外消耗以及运行性能的降低（这个问题也是垃圾回收技术不断升级换代的一个重要原动力）。

本小节中我们来简要分析下Android系统中所采用的GC算法，以便为后面的学习打下一定的技术基础。Android系统中不管是Dalvik或是Art，它们所使用的垃圾回收算法都是以Mark-Sweep为根基演变而来的。

Mark的字面意思是“标记”，在这里指的是对所有内存对象进行遍历处理、统计和标记的过程；相对应的Sweep即是“清扫”过程——依据Mark阶段提供的结论来完成垃圾回收。

Mark-Sweep算法的核心步骤有3个，如下所示：

Step1. 首先，系统中所有Objects对应的Mark Bit都会被清空

Step2. Mark阶段。从GC Root开始遍历系统中的所有对象——只要从“根”开始有一条路径可以到达某个Object，那么我们就可以将它的状态标记为“被引用”，或者更直白地说就是“还有利用价值”

Step3. 系统开始线性地处理堆中的所有元素，并将那些没有被标记为“有利用价值”的对象做Sweep处理。

下面我们再针对上述3个步骤进行扩展说明。

（1）GC的触发时机

我们知道智能指针采用的是引用计数的方式来实现内存的自动化管

理。这就意味着对象引用的每次变更都需要调整计数，直到Count值为0时才回收内存——换句话说引用计数的GC触发条件是Count为0。相对于Reference Counting，GC采用的触发方式在某种程度上效率更高，因为它不需要频繁地为各对象调整计数值，而是选择在某些特定的情况下统一进行处理。那么GC的触发时机应该如何选择才是合理的呢？

以Android系统为例，发生GC的常见场景有如下几种。

- GC_FOR_MALLOC

堆内存已满，而你的程序尝试去分配新的内存块的情况。此时系统需要暂停程序来回收内存。

- GC_CONCURRENT

当堆内存超过特定阈值（Begins to fill up)时，触发的并行GC事件。

- GC_HPROF_DUMP_HEAP

当开发者主动请求创建HPROF（可以参见本书第5章关于程序内存优化的分析)文件来帮助分析堆内存时触发的GC。

- GC_EXPLICIT

“显性GC”，比如程序主动调用gc()函数来完成垃圾回收。不过我们应该尽量避免这种做法，因为理论情况下系统会自动帮你完成这些操作。

由此可见，GC的触发条件大致分为两类：其一是由程序主动请求产生；另一个就是当程序运行过程中分配内存出现（或者即将出现）不足情况时系统做出的主动响应。

（2）GC Root是什么

GC Root是Mark-Sweep中非常重要的角色。试想一下，如果一个活跃有用的对象却在GC后不复存在，那么后果是不堪设想的。因而如何快速有效地区分出“罪犯”与“良民”，是保证GC成功的关键点之一。

Dalvik规定GC Root至少应包含以下这些元素：

① System classes defined by root classloader

② For each thread:

- Interpreted stack, from top to "curFrame"
- Dalvik registers (args + local vars)
- JNI local references
- Automatic VM local references (TrackedAlloc)
- Associated Thread/VMThread object
- ThreadGroups
- Exception currently being thrown, if present

③ JNI global references

④ Interned string table

⑤ Primitive classes

⑥ Special objects

⑦ Objects in debugger object registry

感兴趣的读者可以参考Davlik的官方文档和AOSP工程项目中的源码了解其中的详细信息。

（3）Mark的执行过程

为了让大家更好地理解这一算法的原理，下面我们通过一个范例来做实际分析。如图21-10所示。

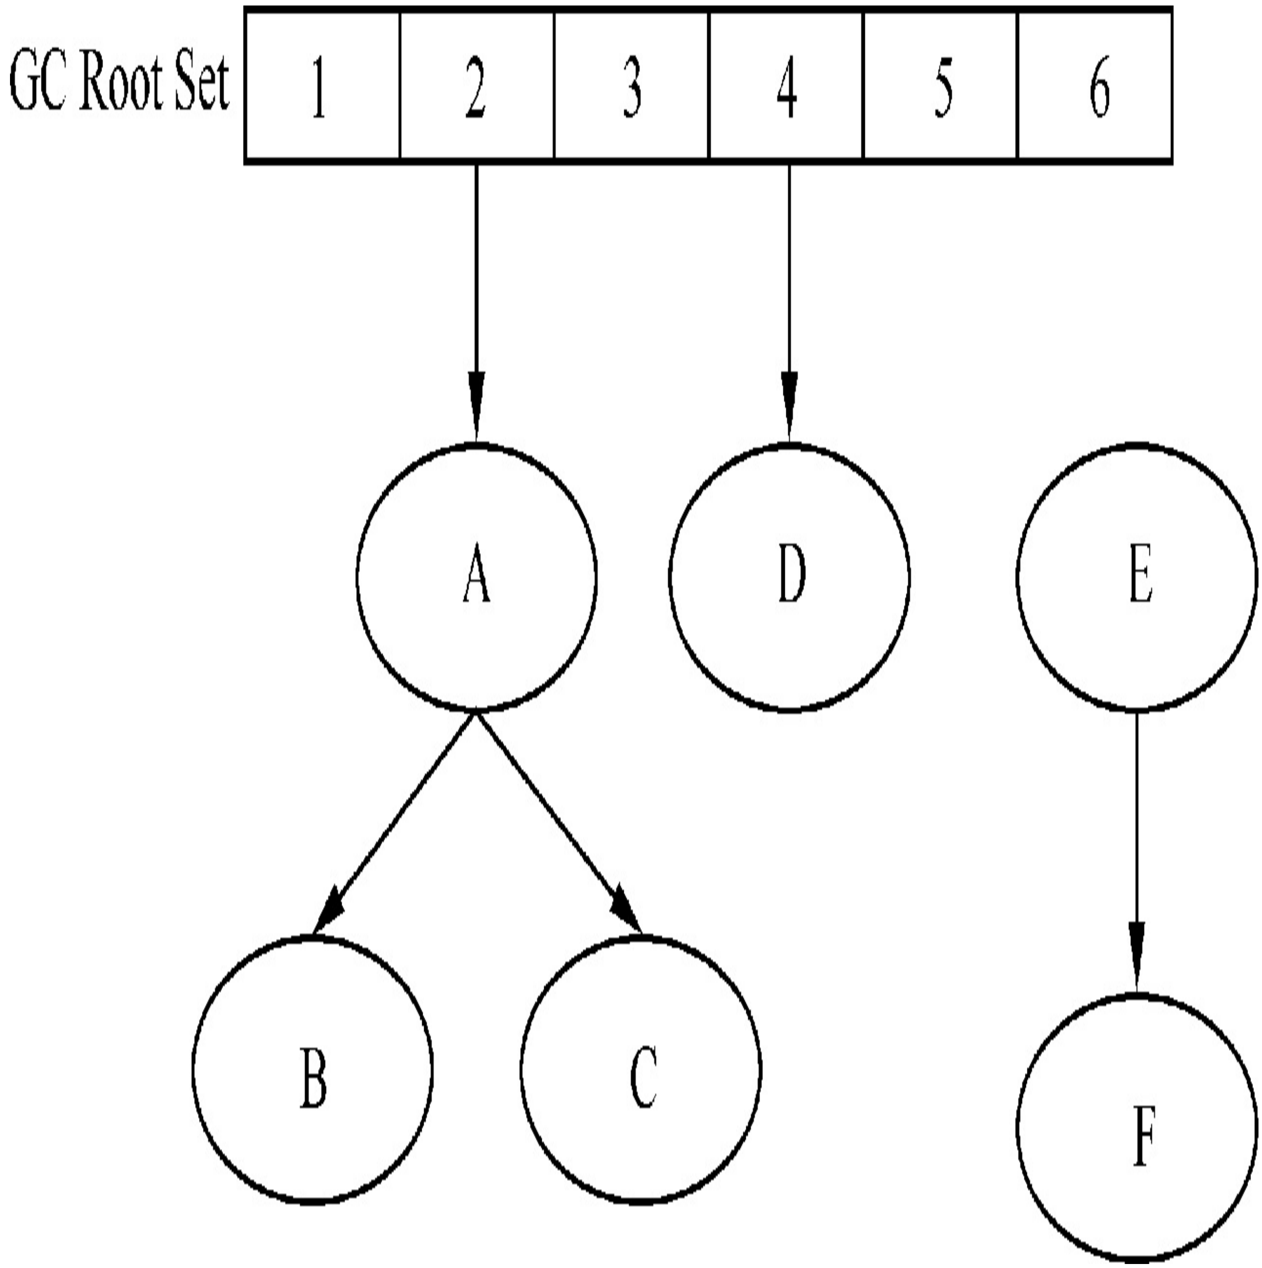

▲图21-10 Mark-Sweep示例

在这个简单的演示图中，GC Root Set共包含了6个对象（当然它们还会分别引用其他对象）。譬如Root 2引用了A，后者又引用了B和C；同理，Root 4引用了D；而对象E则没有被Root Set中的任何元素所引用。

在Mark阶段，系统首先从GC Root Set中的每一个元素出发，逐一遍历它们所引用的各子对象，以及子对象所引用的其他对象——对于从

GC Root出发可以到达的对象（如图21-10中的ABCD），都会被标记在一个名为Mark Heap的Bitmap中，以备后用。更具体地讲，系统从Root节点出发的路径中发现的所有新对象，都会被添加到GC Root Set中，并做好Bitmap的更新；这样当最顶层的GC Root元素全部处理完成后，紧接着就可以分析它们的子元素的引用关系了，直到Set中没有新的元素加入。

在我们这个场景中，在Mark阶段没有被标记的元素是E和F，所以它们将成为下一步Sweep操作中的“被处理对象”。

（4）Sweep的执行过程

有了Mark中的积累，Sweep的执行过程相对来说就顺畅得多了。可选的实现方式也很多，比如线性遍历整个堆来释放没有被标记的对象。Android中除了Mark Heap Bitmap外，还有另一个辅助Sweep的元素，即Live Heap Bitmap。其中LHB记录的是已经分配的对象，而MHB按前面的分析保存的是本次需要存活的对象——这样只要综合这两个Bitmap中的数据就可以准确判断出哪些对象是本轮Sweep的“牺牲品”了。

总体来说，Mark-Sweep算法不仅实现简单，而且比起引用计数又有其自身的优势，因而在GC领域广受欢迎。

21.1.4 Art和Dalvik之争

Dalvik是Android 4.4版本前的标准虚拟机，它成功地支撑了Android系统由“新生儿”蜕变为“青壮年”的整个过程，为Android的发展壮大做出了不可磨灭的贡献。

虽然在当前的Android系统中Art虚拟机已经取代了Dalvik，后者似乎成了“昨日黄花”，但这并不表示Dalvik已然“一无是处”。Art虚拟机事实上是基于Dalvik的深入改造，因而研究后者对于我们理解Art是大有裨益的。有鉴于此，我们将在本小节先对Dalvik的基础知识做一个必要的铺垫。

一个新生事物往往是伴随着问题的解决而出现的，这几乎已经成为科技发展史中“亘古不变”的原则。从这个角度来看，Dalvik也一定是为了解决某种困境或挑战而存在的——而且纵观最近十几年来的技术格局，这种挑战往往不是只来自于技术创新本身，同时也隐含着各个大公

司之间的“政治较量”。

Dalvik的初始作者是Dan Bornstein，据说这个虚拟机的名字起源于其祖先居住过的一个冰岛小渔村。Dalvik出现的时候，Sun公司的Java语言和JVM已经在市面上占据领先地位。那么为什么还需要另起炉灶打造一个不完全归属于JVM阵营的“异类”呢？更为关键的是，这个初期并不为人看好的虚拟机，如何在夹缝之中最终获得了巨大的发展，成就了Android阵营与其他移动操作系统三分天下的局面呢？

Dalvik是面向诸如Android之类的移动设备平台的（我们也不能否认如今移动端和传统PC端的界限已经没有那么明显了，存在互相“入侵”的迹象）。而这些平台的一些“老生常谈”的弱势，就是内存小，处理器能力弱等。如何在这些特殊的环境下解决JVM所存在的一些问题，既是Dalvik所面临的挑战，同时也为它提供了前所未有的机遇。Dalvik所做出的努力包括但不限于：

- 多个Class要能融合进一个Dex文件中，以节省存储空间；
- Dex文件可以在多个进程之间共享；
- 字节码的检验操作是非常耗时的，因而我们最好在应用程序运行之前预先完成；
- 字节码的优化是很有必要的，可以让程序运行得更快，而且更节约电量消耗；
- 为了保证安全性，多个进程间共享的代码不能被随意编辑（只读）。

可以说Dalvik以其更贴近于移动设备的先天优势，支撑了Android系统的茁壮成长。那么为什么后来Google又要摈弃使用了多年且已经日臻成熟的Dalvik，转而投向Art的怀抱呢？

简单来讲，还是“运行速度”。

Android从诞生以来就背负了一些沉重的包袱，其中之一就是“系统庞大，运行慢”。除了本书其他章节讲解的“Project Butter”外，对虚拟机的大力改造也是Android企图脱离困境所做出的尝试之一。

于是Art从Android 4.4开始，以和Dalvik暂时共存的形态正式进入了人们的视野。因为Android 4.4时Art还处于Preview状态，所以

Google官方提供了如下的声明：

“Art is a new Android runtime being introduced experimentally in the 4.4 release. This is a preview of work in progress in KitKat that can be turned on in Settings > developer options. This is available for the purpose of obtaining early developer and partner feedback.”

在Kitkat的系统设置中，我们可以找到如图21-11所示的系统选项。

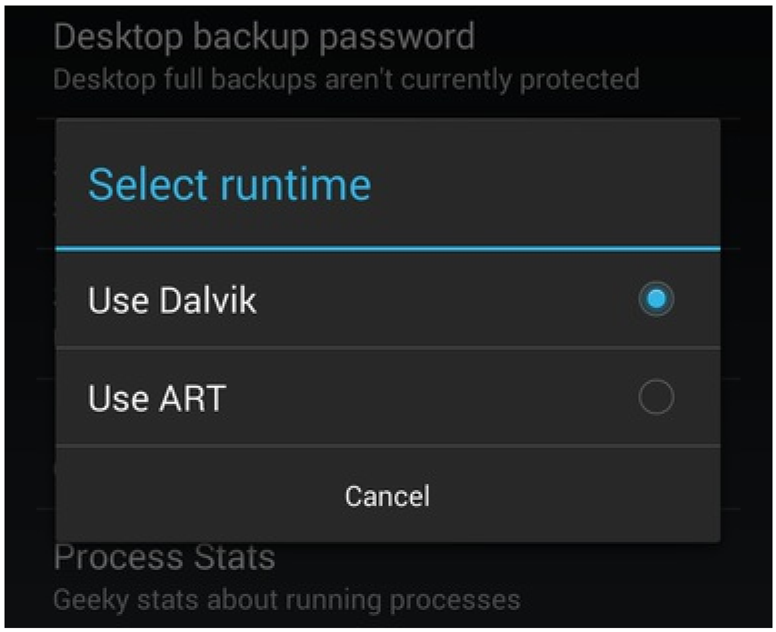

▲图21-11　子流选项

随后Art便再接再厉，并在2014年6月26日Google I/O大会上发布的Android Lollipop中正式取代了Dalvik的位置。

接下来我们用数据说话（见图21-12和图21-13），看下Art在性能上相对于Dalvik有多大的改善。

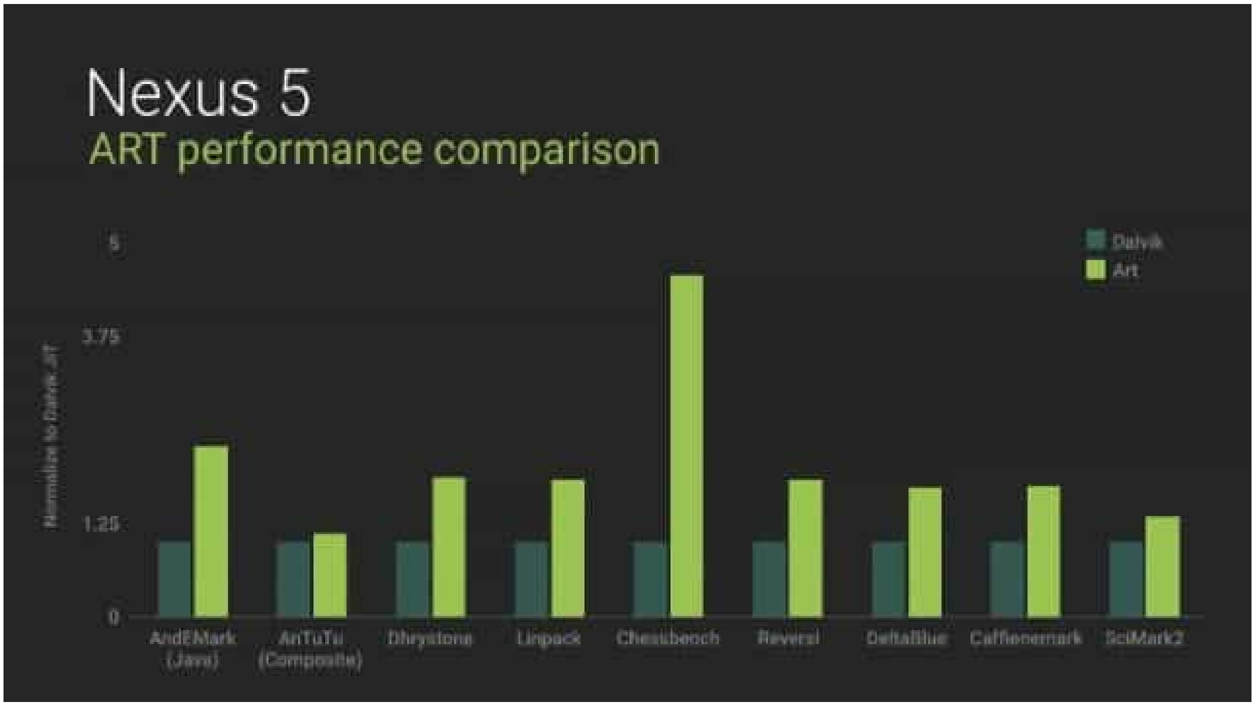

▲图21-12　引用自Google I/O 2014 Keynote

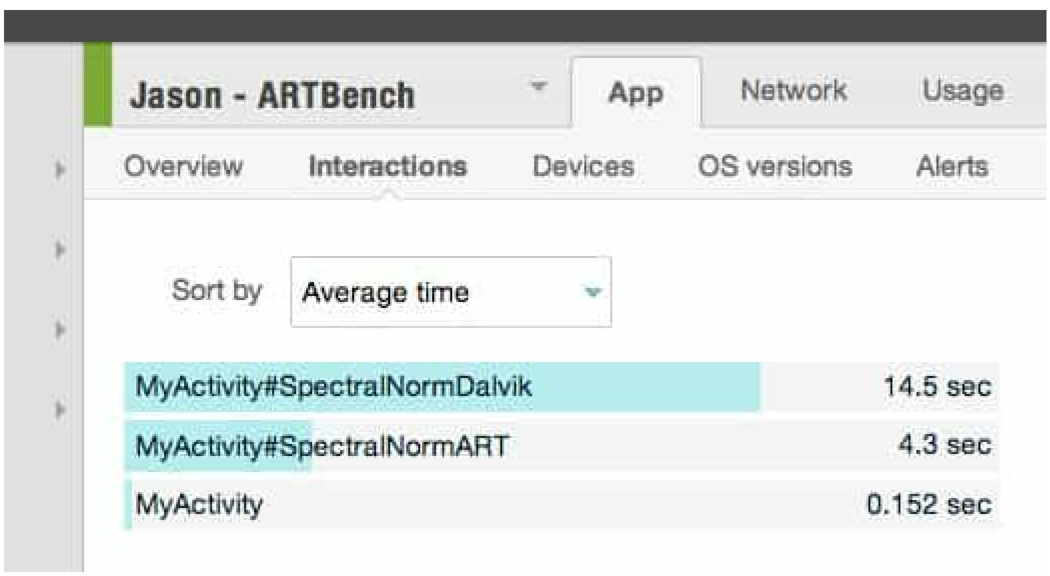

▲图21-13　引用自newrelic.com

通过上述Art与Dalvik的对比图，我们可以看到前者在性能上确实有显著优势。其中newrelic.com考核的是两个相同的应用程序分别在启用了Art和Dalvik虚拟机的GenyMotion模拟器上启动速度——不难发现，运行于Art之上的应用程序快了3倍！

产生这种差异的主要原因在于Dalvik虚拟机多数情况下还是得通过解释器的方式来执行Dex数据（JIT，即Just in Time技术虽然可以在一定程度上提高效率，但也仅仅是针对一小部分情况，作用有限）；而Art虚拟机则采用了AOT（Ahead of Time）技术，从而大幅提高了性能。我们需要理解以下几个要点。

- Dex是一种字节码格式，是Dalvik虚拟机中的可执行文件。
- Dalvik采用了JIT技术来将频繁执行的字节码编译成目标平台上的机器码。JIT区别于AOT的一个主要特征是，它只有在程序运行过程中才会将部分热点代码编译成机器码——而且这在某种程度上也加重了CPU的负担。
- AOT如其字面意思所示，会提前将Java代码翻译成针对目标平台的机器码，从而避开了JIT的上述不足。当然，这也就意味着如果是采用了AOT技术的ROM方案，那么Android的编译时间将会有所增加。不过由于Android系统的构建原本就比较慢，所以这点牺牲还是值得的。另外，第三方APK事先并不知晓它将安装和运行于哪个具体的硬件平台之上，所以，对于这些APK来说肯定不能以AOT的形式发布。不过，当它们在配备了Art虚拟机的设备上安装时，后者会调用一个精简的编译器（dex2oat)来完成动态的“翻译”工作。这样才能有效地保证第三方应用程序与系统预装的应用程序保持同样的运行效率。我们在后续小节还会有专门的介绍。

21.1.5 Art虚拟机整体框架

Art虚拟机整体框架如图21-14所示。

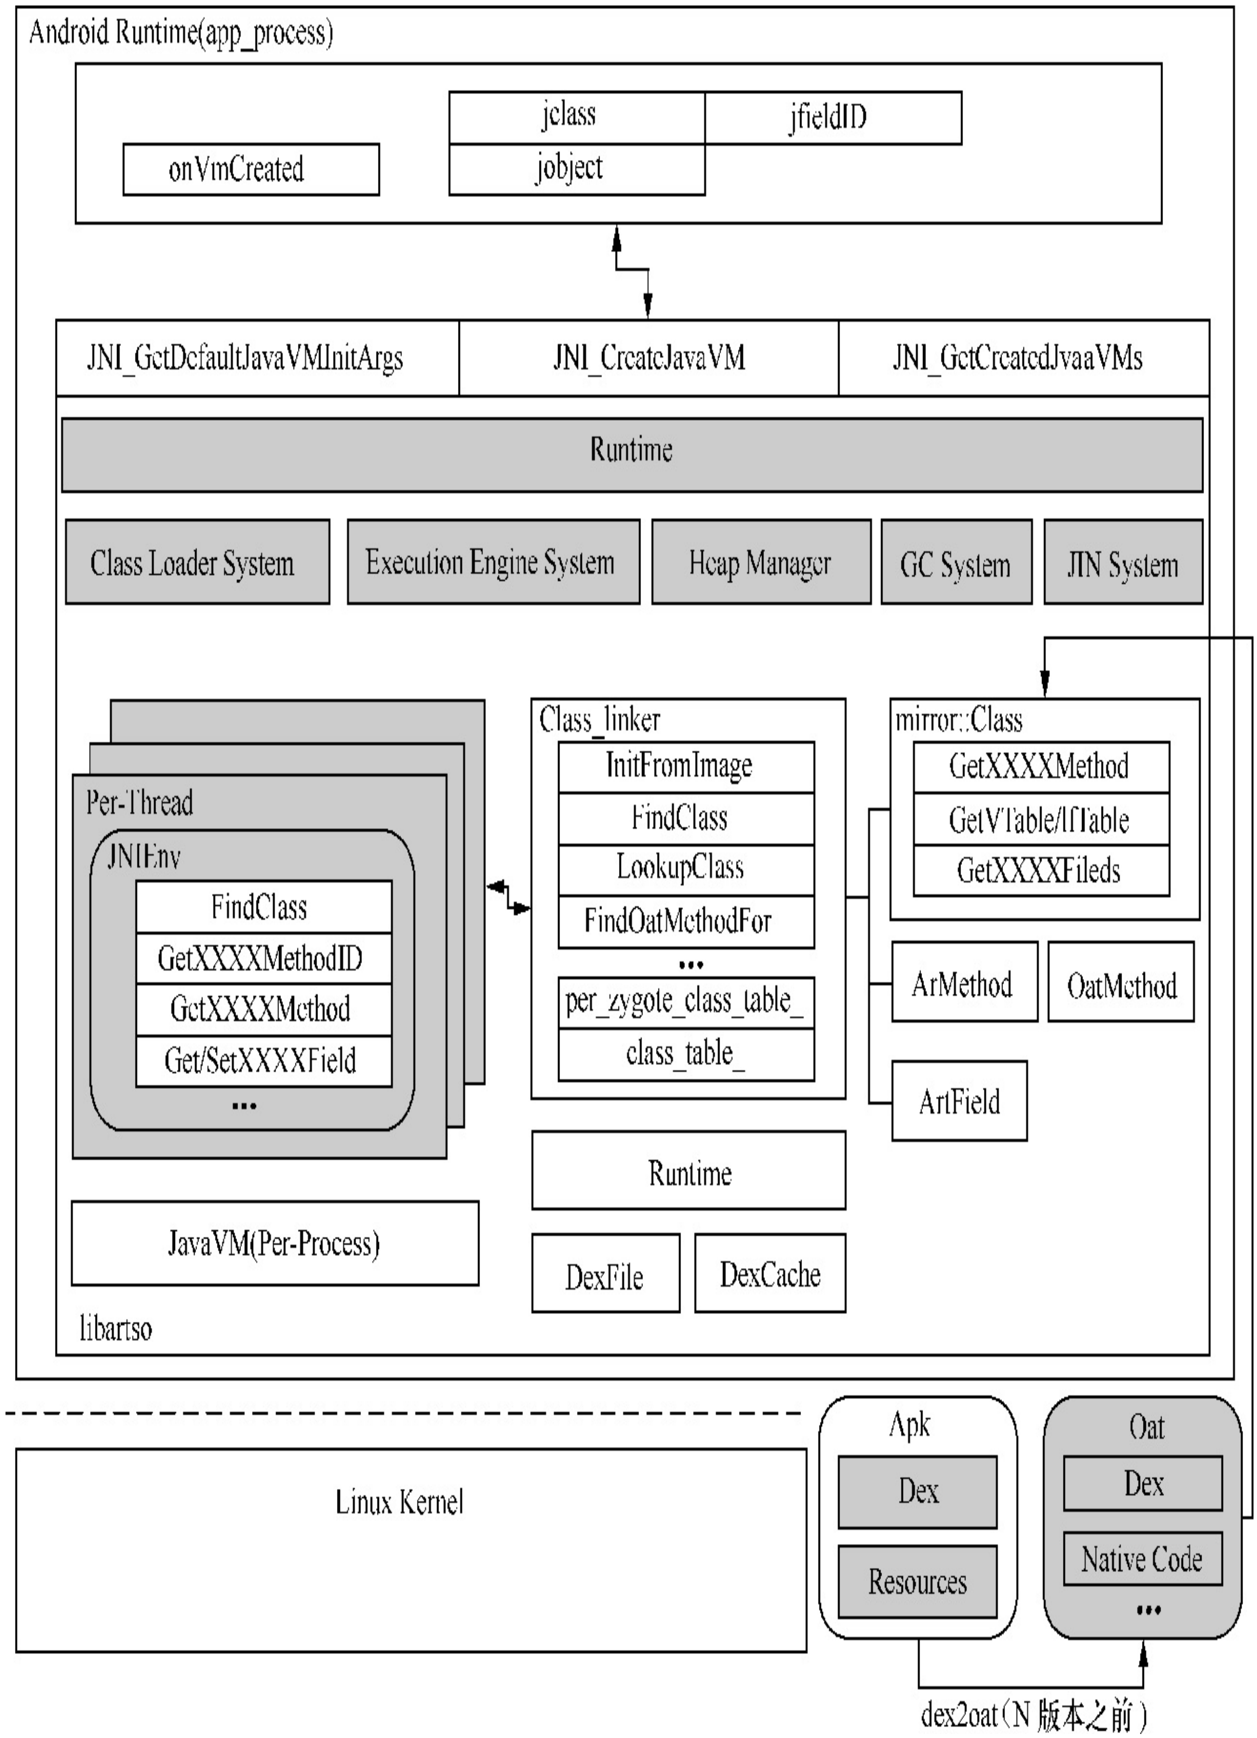

Android Runtime(app_process)
onVmCreated
jclass
jfieldID
jobject
JNI_GetDefaultJavaVMInitArgs
JNI_CreateJavaVM
JNI_GetCreatedJvaaVMs
Runtime
Class Loader System
Execution Engine System
Heap Manager
GC System
JIN System
Per-Thread
JNIEnv
FindClass
GetXXXXMethodID
GetXXXXMethod
Get/SetXXXXField
...
Class_linker
InitFromImage
FindClass
LookupClass
FindOatMethodFor
...
per_zygote_class_table_
class_table_
mirror::Class
GetXXXXMethod
GetVTable/IfTable
GetXXXXFileds
ArMethod
OatMethod
ArtField
Runtime
JavaVM(Per-Process)
DexFile
DexCache
libartso
Linux Kernel
Apk
Dex
Resources
Oat
Dex
Native Code
...
dex2oat（N 版本之前）

▲图21-14　虚拟机整体框架

Android虚拟机从诞生到现在，主要经历了两个大的平台，即Art和Dalvik。

Dalvik迁移到Art实现对于Android虚拟机而言是一个很大的变动，我们应该如何保证二者之间的无缝切换呢？Google给出的解决方案是将虚拟机“黑盒化”——无论是Dalvik、Art或者是未来可能出现的任何新型虚拟机，它们提供的功能将全部被封装在一个.so库中，并且对外需要暴露JNI_GetDefaultJavaVMInitArgs、JNI_CreateJavaVM和JNI_GetCreatedJavaVMs三个接口（不排除后续会增加新接口）。使用者（比如Zygote）只需要按照统一的接口标准就可以控制和使用所有类型的Android虚拟机了，这样一来就很好地保证了它们的无缝对接。

组成Android虚拟机的核心子系统包括但不限于：Runtime、ClassLoader System、Execution Engine System、Heap Manager和GC系统、JIT、JNI环境等。

Runtime如其名所示，代表了虚拟机的运行时态，起到了“大总管”的作用；JavaVM是对虚拟机的抽象，每个进程中最多只有一个实例存在；JNIEnv负责JNI（Java Native Interface）机制，即解决Java与C/C++等本地语言之间如何互相通信的问题。需要特别注意的是，JNIEnv是线程相关的。

和标准的JVM一样，类加载器在Android虚拟机中也扮演着很重要的作用。它又可以被细分为Boot ClassLoader、System ClassLoader、DexClassLoader等。所有被加载的类和它们的组成元素都将由ClassLinker做统一的管理。另外，为了实现类似于ELF中的动态延迟加载的效果，Android虚拟机中还使用了DexCache机制。我们在后续小节还会有更详细的分析。

Execution Engine是虚拟机的“动力系统”。除了字节码解释执行的方式（内部又可以借助于JIT来实现加速）外，Art虚拟机还支持通过AOT来直接执行字节码编译而成的机器代码（Android N版本之前）。这其中还涉及很多细节问题，比如：

- 在什么时候执行编译工作

在M版本的Android Art虚拟机中，AOT的编译时机有两个，即随Android ROM构建时一起编译，以及在程序安装时执行编译（针对第三方应用程序的情况）。我们在后续内容中将通过两个小节来分别讲解这两种编译时机。

- 编译后的机器代码如何存储

我们将通过一个小节来分析Art虚拟机中引入的新的存储格式，即OAT文件（事实上属于ELF文件的变种，因而我们在讲解OAT之前还会用专门的小节来为大家补充背景知识）。

- 虚拟机如何加载字节码及OAT机器码

加载字节码自然会涉及ClassLoader的相关知识；加载OAT则需要用到ELF的基础能力。我们将利用若干小节的篇幅来专门讲解这些知识，以帮助大家更好地理解Art虚拟机。

- 如何执行字节码和OAT机器码

因为程序中同时有字节码和机器码，那么在具体执行时该如何抉择，当遇到需要从字节码切换到机器码（反之亦然）的情况时又应该怎么应对呢？这些都将在本章节得到详细的阐述。

另外，由于“一股脑”地在程序安装阶段将Dex转化为OAT造成了一定的资源浪费，所以从Android N版本开始Art虚拟机又改变了之前的OAT策略——程序在安装时不再统一执行dex2oat，而改由根据程序的实际运行情况来决定有哪些部分是需要被编译成本地代码的。这样一来Android N版本中的Art虚拟机就又回到了“三足鼎立”的时代，即：Interpreter、JIT和OAT三分天下的局面。

本章剩余内容的编排大致如下：

（1）Android虚拟机的基础知识，包括ELF、OAT、Dex字节码等的详细分析；

（2）Android虚拟机的类加载系统（ClassLoader，ClassLinker等）；

（3）Android虚拟机的堆内存管理；

（4）Android虚拟机的执行引擎，这是本章的重中之重，将涵盖OAT、解释器和JIT三种类型的执行方式；

（5）与Android虚拟机相关的其他信息，包括Native Bridge、JDWP、如何调试虚拟机等内容。

21.1.6 Android应用程序与虚拟机

虚拟机只能算是一个“舞台”，真正给观众带来“视觉盛宴”的还是台上的各“主角”们，即Android应用程序。我们对舞台的基本要求是至少不能拖演员们的“后腿”——就好比同一场话剧，不能因为北京和上海的舞台差异而导致演出效果的大幅降低（甚至是需要演员们根据舞台的特点来增、删、改戏本），否则就是一个非常失败的舞台。平心而论，Android虚拟机这个大舞台虽然一直在“装修改造”（例如全新舞台Art的出现，Dalvik的不断更新换代等），但“主角”们确实没有因此而受到太多的影响——这就说明了Android系统这个“大导演”在处理“舞台问题”上的确有其独到之处。

那么Android应用程序与虚拟机之间是如何保持这种默契的呢？

首先，Android为应用程序的编译、打包等过程提供了一系列完整的工具支撑，使得开发者可以不需要特别关心系统的底层实现。

其次，Android应用程序的文件结构是相对稳定的。图21-15所示的是一个可以运行于最新Android N版本上的APK应用程序的内部典型构成。

名称			类型
assets			文件夹
lib			文件夹
META-INF			文件夹
R			文件夹
com			文件夹
BeaconVersion.txt	5	5	文本文档
AndroidManifest.xml	236,428	23,512	XML 文档
resources.arsc	1,393,808	1,393,808	ARSC 文件
classes.dex	9,183,328	3,809,222	DEX 文件
classes2.dex	9,284,832	3,742,401	DEX 文件
classes3.dex	8,916,136	3,788,998	DEX 文件

▲图21-15 应用的内部构成

不难发现，对于开发人员而言应用程序的编译过程是“透明”的，而且APK中的可执行文件也一直保持Dex不变。这些都没有因为Android虚拟机的升级换代而发生变更。这样就保证了Android应用程序不会因为“舞台”的升级而需要不断地“改弦易辙”。

大家可能还有一个困惑的地方——Dalvik和Art这两个差别巨大的虚拟机，对应用程序本身却没有什么特殊要求，那么真正的“分水岭”会在哪里呢？我们可以先看一下Google 在I/O会议上官方发布的一张关于APK生命周期的示意如图21-16所示。

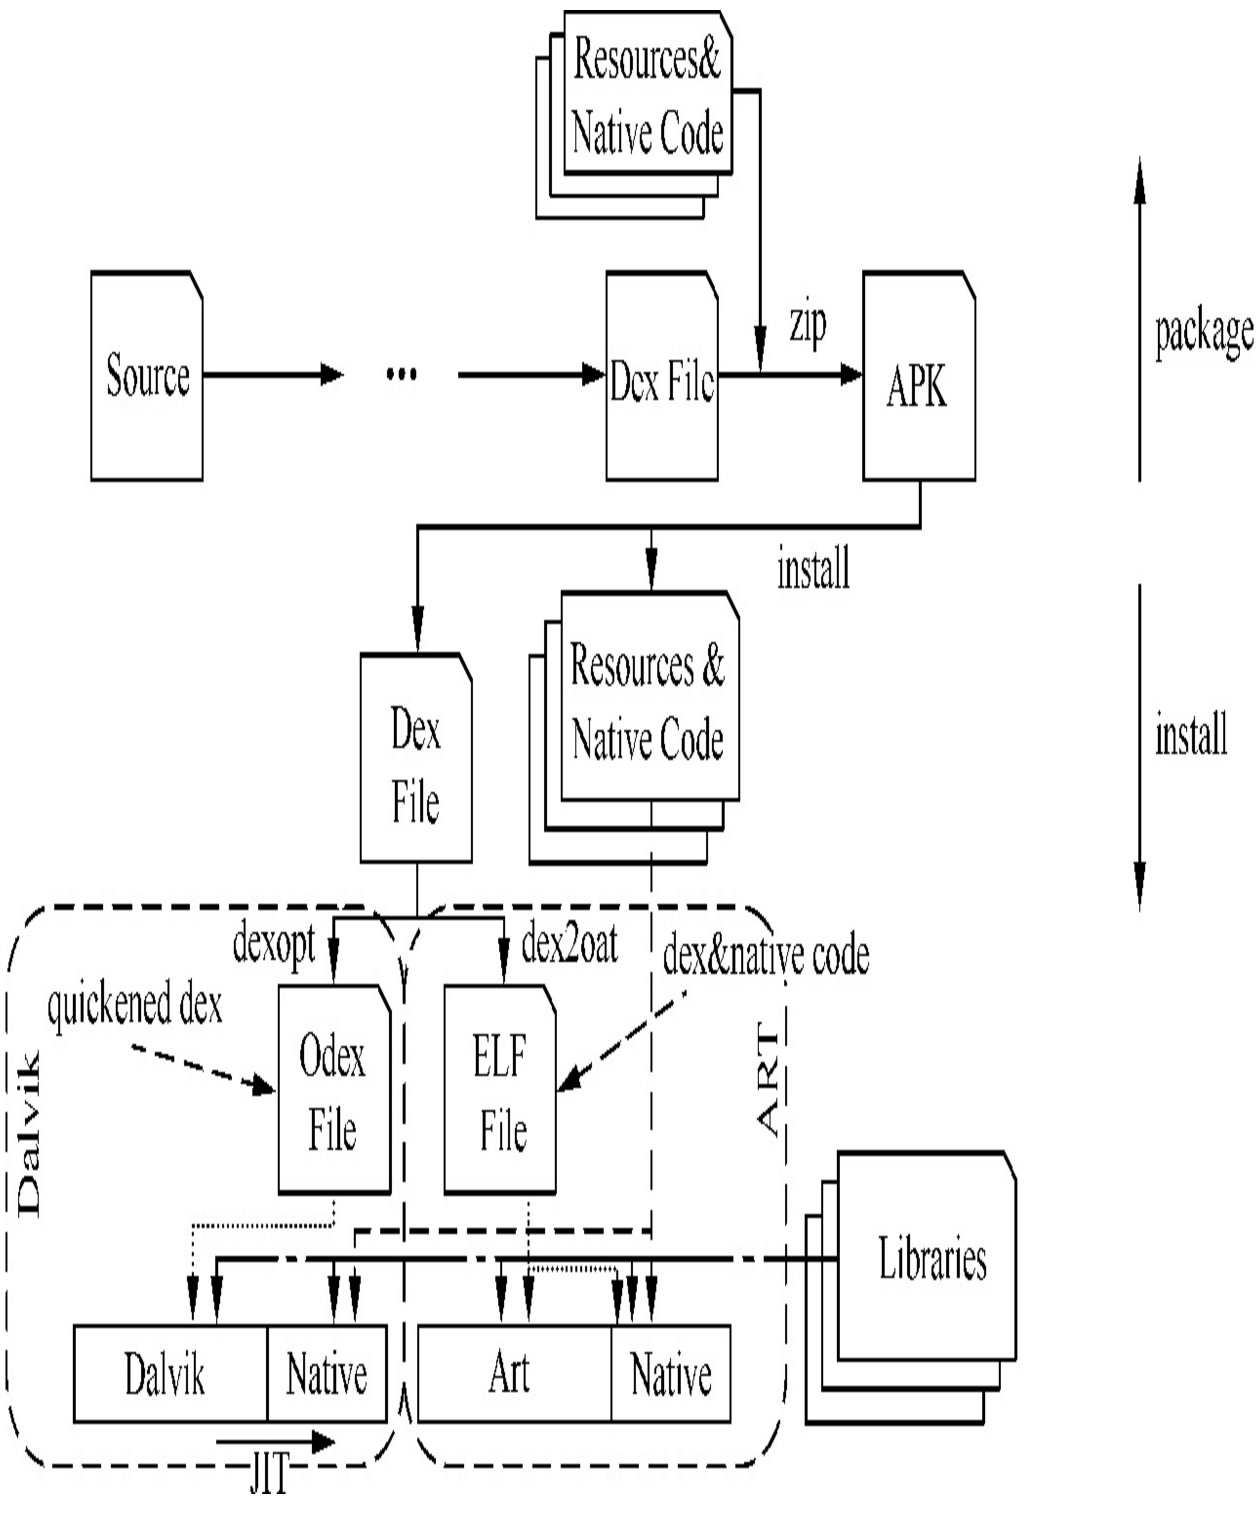

▲图21-16　APK生命周期

我们将产生APK的过程称为Package阶段，与之相对应的则是APK的安装阶段。从图21-16中可以清晰地看到，虚拟机的具体类型（譬如Art

或Dalvik）对于应用程序的Package阶段是100%透明的。

真正的“分水岭”出现在应用程序的安装阶段。具体来讲，Android系统在安装APK的时候，它需要根据当前的虚拟机类型而做区分处理。

- Dalvik

如果系统设备配备的是Dalvik虚拟机，那么在应用程序安装阶段需要对Dex文件做Odex优化处理。简单而言就是利用dexopt工具来生成Odex文件，不过还应该细分为如下几种情况：

情况1：打包到系统ROM中的APK，即预装的应用程序。这种情况下编译系统具有绝对主动权。换句话说，优化过程在编译阶段就完成了。而且完成优化操作后，我们可以选择是否将jar（或者APK）文件中的classes.dex移除，再把Odex放到与原jar/APK的同级目录下。这种处理方式既保证了应用程序运行时的效率，同时还节省了存储空间。

情况2：针对非系统预集成的第三方应用程序，会在安装阶段由installer系统程序来负责优化操作，最终结果会被保存到/data/Dalvik-cache目录下，并以.odex为后缀名。

情况3：针对第三方应用程序还有另一种可能性，就是等到它运行时再执行优化操作（这种方式有点类似于“Just in time”）。不过由于应用程序并不一定具备对dalvik-cache的写操作权限，所以这种方式通常只在开启了工程模式的设备中才有效果。

- Art

如果当前系统使用的是Art虚拟机，那么应用程序在安装阶段同样也会有一次预处理（和Dalvik中的情况一样，如果是ROM预置的APK，那么处理时机会有所不同）——只不过Art虚拟机中预处理所使用的工具是dex2oat，输出的则是Linux的标准可执行文件，即ELF File。

这样一来我们就能保证应用程序在“无感知”的情况下兼容各种类型的虚拟机了。

21.1.7 Procedure Call Standard for Arm Architecture（过程调用

标准）

在后续讲解Art虚拟机如何执行机器码之前，我们还有一个非常重要的基础知识需要补充，即Procedure Call Standard（过程调用标准）。PCS是汇编程序中调用和被调用方之间的一种约定，只有严格遵守约定才能保证程序的正常运行。不同体系结构下的PCS会有些差异，其中针对ARM的标准是AAPCS（Procedure Call Standard for Arm Architecture）。相关标准的释义及关系如下所示：

PCS	Procedure Call Standard.
AAPCS	Procedure Call Standard for the ARM Architecture (this standard).
APCS	ARM Procedure Call Standard (obsolete).
TPCS	Thumb Procedure Call Standard (obsolete).
ATPCS	ARM-Thumb Procedure Call Standard (precursor to this standard).

任何高级语言被翻译成机器代码后，也都需要遵循PCS，这样才能保证它们在目标平台上被正确执行。根据ARM规范中的定义，Procedure和Function是有区别的，如下所示：

Procedure	A routine that returns no result value.
Function	A routine that returns a result value.

那么Routine又应该如何理解呢？

Routine, Sub-routine: A fragment of program to which control can be transferred that, on completing its task, returns control to its caller at an instruction following the call. Routine is used for clarity where there are nested calls: a routine is the caller and a subroutine is the callee.

简单来说，AACPS是Subroutines可以被独立编写、编译并能与其他模块完美协同工作的基础——或者说它是调用者（Calling Routine）

和被调用者（Called Routine）之间的一个非常严格的协议规范。

我们知道，大多数硬件平台都有其通用和特殊用途的寄存器，它们将在CPU执行代码的过程中发挥重要作用。ARM系统当然也不例外。所以要正确地理解AAPCS，首先我们需要对ARM架构中的寄存器，以及它们在PCS中扮演的角色有一个清晰的认识，如图21-17所示。

AAPCS适用于进程中的单个线程；而每一个进程（Process）都有它自己的Program State，后者由相应的机器寄存器和一些进程可以访问到的内存（如果不是该进程可以访问到的范围，将产生异常）中的内容来表示。根据ARM规范中的描述，一个进程中的内存区域可以大致分为如下几类：

- 代码区域;
- 只读的静态数据区域;
- 可写的静态数据区域;
- 堆区域;
- 栈区域。

Register	Synonym	Special	Role in the procedure call standard
r15		PC	The Program Counter.
r14		LR	The Link Register.
r13		SP	The Stack Pointer.
r12		IP	The Intra-Procedure-call scratch register.
r11	v8		Variable-register 8.
r10	v7		Variable-register 7.
r9		v6 SB TR	Platform register. The meaning of this register is defined by the platform standard.
r8	v5		Variable-register 5.
r7	v4		Variable register 4.
r6	v3		Variable register 3.
r5	v2		Variable register 2.
r4	v1		Variable register 1.
r3	a4		Argument/scratch register 4.
r2	a3		Argument/scratch register 3.
r1	a2		Argument/result/scratch register 2.
r0	a1		Argument/result/scratch register 1.

▲图21-17　ARM体系中的寄存器以及它们在PCS中所扮演的角色（引用自ARM公司的官方资料《Procedure Call Standard for the ARM® Architecture》）

其中可写的静态数据区域又可以细分为已初始化、清零初始化和未初始化的数据区。

另外无论是ARM或者是Thumb指令集（网络上有不少关于这两种指令集之间的区别与联系的资料，建议大家可以自行参阅学习），它们都提供一条Primitive调用指令，即BL。这条指令会将PC（Program Counter）寄存器的下一个值保存到链接寄存器（Link Register）中，并且把BL需要跳转的目标地址存入PC中（另外，在Thumb状态下执行BL指令时，LR中的Bit0位会被置为1；反之在ARM状态下会被置为0）。这样做的目的，一方面是保证程序可以正确地跳转到目标地址中去执行代码，另一方面BL执行完成后可以通过预先保存在LR中的值顺利返回到之前的状态。

还有一个与AAPCS有关联的规范是ATPCS，它是AAPCS的前身。ATPCS是保证C语言与汇编语言可以混合编程的关键，请大家重点思考以下两点。

（1）参数的传递

参数的传递方式有两种，即参数个数可变以及参数个数不可变的情况。

以参数个数可变的情况为例，其处理逻辑如下：

- 将参数存入a1-a4中，如果参数个数小于4，则只需要用到a1-a3（3个参数）或者a1-a2（2个参数）或者a1（1个参数）；
- 如果参数个数大于4，则将上一步中未处理完的参数以逆序的方式存入栈中，即剩余的第1个参数存入VAL(SP)，第2个参数存入VAL(SP)+4，以此类推。

（2）返回值的处理

函数的返回值有可能是Integer或者Floating-Point，而且所占用的空间可能是1个或者多个Words。以Integer的情况为例，返回值的具

体处理策略是：

- 如果是1-word value，则保存在a1中；
- 如果是2-4 words，则分别对应a1-a2、a1-a3、a1-a4；
- 对于需要占用更多words的情况,则需要通过额外的内存地址参数来传递返回值。

在后续小节的学习过程中，我们会发现Android虚拟机并没有完全遵循AAPCS，而是在它的基础上做了适当的定制（例如用r9寄存器来记录Thread信息）。请大家结合起来阅读理解。

21.1.8　C++ 11标准中的新特性

Android虚拟机子系统主要是用C++和汇编语言编写完成的，其中运用了大量的C++ 11特性。本小节我们主要讲解C++ 11相对于C++语言老版本标准的一些差异特性，为大家阅读虚拟机的代码实现扫清障碍。

21.1.8.1　智能指针unique_ptr

我们在本书操作系统基础知识章节已经详细分析过Google提供的智能指针方案及它的基本原理了，可以说它和Android虚拟机内部使用的C++中的智能指针具有“异曲同工”之效。

C++中共有4种类型的智能指针，即：auto_ptr、unique_ptr、shared_ptr和weak_ptr。第一种auto_ptr在C++11中已经被摒弃了，大家可以不用再做进一步了解。另外几种在Android虚拟机中使用频率最高的则是unique_ptr，因而我们作为本小节的重点来做讲解。

顾名思义，unique_ptr说明该智能指针所管理的对象只允许有一个引用，与之相对的是shared_ptr。当unique_ptr自身被销毁的时候，它所管理的对象也会被同步释放回收，以避免内存泄露的发生。

unique_ptr中包含的主要成员函数如表21-2所示。

表21-2　主要成员函数

Member	Description

functions	
（constructor）	构造函数
（destructor）	析构函数
operator=	为智能指针管理的对象赋值
get	获取智能指针所管理的对象，返回值有可能是nullptr要特别注意执行get函数后，unique_ptr仍拥有对目标对象的管理权，因而调用者不能将返回值用于构建另一个智能指针，否则会出现错误
release	释放智能指针所管理的对象，意味着unique_ptr将失去对目标对象的管理权

下面举一个简单的例子来说明unique_ptr的用法与作用：

```
void test_uniqueptr()
{
    TEST_XX * u_ptr = new TEST_XX;
    …
    delete u_ptr;
}
```

上述函数中的TEXT_XX对象的释放完全取决于最后一个delete语句的执行，属于不可靠的方式：

```
void test_uniqueptr2()
{
    unique_ptr<TEST_XX> u_ptr(new TEST_XX);
    …
    delete u_ptr;
```

```
}
```

当u_ptr对象的生命周期结束的时候，其析构函数必然会被调用，同时被销毁的还包括TEST_XX对象，从而避免了内存泄露的情况。

当然，这只是unique_ptr的一个典型使用场景。大家可以与后续小节中的虚拟机源码分析结合起来学习。

21.1.8.2 类型自动推导auto

旧版本的C++规范要求源码中必须显式声明各个变量的类型，这就是我们所说的强语言行为。而C++ 11中改变了这种状态，它允许开发人员使用auto来代替变量的类型声明，然后由系统来自动推导出变量的真实类型。相信这种能力大家在脚本语言中已经“见怪不怪”了——这也从侧面说明了C++为了提升开发者便捷性，借鉴和吸收了其他不少编程语言的优秀特性。

下面是使用auto的一个小范例，供大家参考：

```
auto a = 10;
auto c = 'A';
auto s("hello");
```

值得一提的是，C++ 11提供的类型自动推导功能事实上是由编译器完成的，这样一来就可以保证程序在运行过程中的性能不受到影响了。不过这同时也提醒我们，使用auto变量的一个前提条件是能提供足够的信息来供编译器完成自动推导，例如给变量做初始化。而诸如下面这样的场景显然会导致编译错误：

```
auto m;
```

21.1.8.3 空指针nullptr

在C++旧版本的规范中，开发人员已经习惯于通过NULL来初始化一个空指针了。NULL通常会被定义为（void *）0或者0，范例如下所示：

```
#ifndef NULL
#ifdef __cplusplus
 #define NULL    0
#else
```

```
 #define NULL    ((void *)0)
#endif
#endif
```

NULL的不足则在于它在某些场景下有可能会产生二义性。

举一个例子来说，下面是两个重载函数：

```
void my_function(float *);
void my_function(int);
```

如果我们希望调用的是第一个函数（float*），而且传递的参数为空指针，那么在以往的表达方法中，就变成了：

```
my_function（NULL）；
```

由于NULL本身也是0（属于int类型），所以上述的函数调用并没有办法确定程序的“真实意图”——二义性就此产生。

为了避免不必要的麻烦，C++ 11标准中引入了关键字nullptr来解决类似的问题。

它的典型范例如下：

```
ArtMethod* method_ = nullptr;
if (r == nullptr) return 0;
```

21.1.8.4　原子操作和原子类型

原子操作简单来讲是指“A sequence of one or more machine instructions that are executed sequentially, without interruption”，即不可中断的一个或多个机器指令的执行过程。

原子操作的实现和具体的硬件平台有直接关系。单处理器的情况下，由于中断只能发生在指令之间，所以单条指令可以完成的操作都可以被认为是原子的。多处理器的情况则会更复杂一些，因为我们很难保证多个处理器的具体执行时间。通常我们会有如下几种典型的方法来解决这类问题。

- 利用总线锁来实现原子操作

总线锁实际上是处理器芯片提供的一个LOCK信号。当某个处理器输出这一信号时，总线会保证暂时不处理其他处理器的请求，从而满足单个处理器独占内存的要求。

- 利用缓存锁来实现原子操作。

总线锁在工作期间内，其他处理器与内存之间的通信都被“截断”了，显然这样的做法相当“霸道”，性价比不高。缓存锁可以在某些场景下代替总线锁，确保在完成同样功能的情况下降低开销。

原子操作的具体硬件实现方式有很多，为此C++ 11标准中提供了专门的软件“封装”来帮助开发人员屏蔽这些硬件上的差异性，同时还能更方便地解决部分同步问题。

以出售火车票为例，假设余票数量为count，那么传统的做法需要通过互斥锁等手段才能保证正确性。而在C++ 11中，我们可以直接将count声明为原子类型（如atomic_int），然后资源竞争的问题就可以交由编译器来解决了。提供这个特性的头文件是<atomic>，其中常见的数据类型都有它们对应的原子类型，譬如atomic_bool、atomic_char、atomic_schar（signed char）、atomic_uchar（unsigned char）、atomic_short、atomic_ushort（unsigned short）、atomic_int、atomic_uint（unsigned int）等：

```
#include <atomic>
atomic_int count(10000);
```

除此之外，C++ 11标准还提供了模板类atomic来帮助大家扩展自己的“原子类型”。Art虚拟机中的Atomic就是通过这种方式实现的，如下所示：

```
/*art/runtime/atomic.h*/
template<typename T>
class PACKED(sizeof(T)) Atomic : public std::atomic<T> {
 public:
  Atomic<T>() : std::atomic<T>(0) { }

  explicit Atomic<T>(T value) : std::atomic<T>(value) { }
…
```

C++提供的原子操作在运行效率上做了不少优化，因而在Art虚拟机

中使用比较多。

21.1.8.5 Lambda

Lambda是希腊字母的第11位（Λ λ，国际音标/'læmdə/），以它命名的表达式在不少编程语言中都存在，例如C++、Python、Java（从8开始）、JavaScript等。

不过不同编程语言（甚至是同种语言不同编译器）对于Lambda的具体表达方式存在一定的差异。在C++ 11标准中，Lambda遵从如下的格式：

```
[capture](parameters) mutable exception-> return_type { function
```

capture：“捕获”列表，它同时也是Lambda表达式的起始标志，用于指示可以使用的上下文变量。常见的范例如下所示：

[] 捕获列表为空的情况下，所有外部变量在Lambda表达式中都不可以访问；

[x, &y] 表示x变量以值传递的方式捕获，而y变量以引用的方式捕获；

[&] 表示所有外部变量都以引用的方式捕获；

[=] 表示所有外部变量都以值传递的方式捕获。

parameters：参数列表，这和普通函数的定义是类似的。

exception：此表达式是否会抛出异常，以及异常的类型

return_type：返回值类型，即Lambda表达式的返回结果的数据类型。

function_body：lambda表达式的内部实现。它除了可以像普通函数一样使用Parameters外，还可以根据Capture中的设置来访问外部变量。

下面我们举个例子来帮助大家进一步理解Lambda：

```
std::vector<int> List{ 1, 2, 3, 4, 5 };
int total = 0;
int value = 5;
std::for_each(begin(List), end(List), [&, value, this](int x) {
    total += x * value * this->XXX_FUNC();
});
```

上述代码段实现的是列表的遍历功能。从[]列表可以看出除value和this指针以值传递的方式来捕获之外，其余变量都以引用的方式传递。值传递意味着在Lambda表达式定义时该变量的值就已经被确定下来了，而引用传递则是指Lambda被调用时才会确定变量的值；参数列表中只有x个变量。因为这个Lambda没有返回值，此种情况下允许省略掉“->”。

关于Lambda还有很多应用场景，建议大家可以参阅相关资料做进一步了解，限于篇幅我们暂不做过多阐述。

21.2 Android虚拟机核心文件格式—— Dex字节码

Java最重要的特性是“Write once, run anywhere”（WORA），这也是它得以快速发展的原始驱动力。不过要做到这一点并不容易，Java首先要解决的棘手问题就是如何让这门高级语言所编写的代码让形态各异的目标平台们所“理解”。

字节码就是上述问题思考的结果。

字节码又被称为“P-Code”（Portable Code），是一种“承上启下”的指令集。“承上”是指Java代码，而“启下”针对的是具体的硬件平台。在大部分情况下，Java代码在编译阶段首先会被转换为Bytecode，然后在运行过程中再通过Interpreter（解释器）来解释执行。不过需要大家特别注意的是，由于现在大部分的虚拟机都支持JIT（Just In Time）功能，所以并非所有场景下都需要解释器的参与。示意图如图21-18所示。

Android中的字节码和标准JDK相比有其特殊之处。根据Google提供的官方文档，Android在设计Bytecode时所采用的核心原则如下。

（1）Bytecode的机器模型（Machine Model）和调用规范（Calling Conventions）应该尽可能模拟通用的真实机器框架，以及C-Style的调用规范。

Dalvik是基于寄存器的（Register-Based。可以参见前面小节的分析）虚拟机，而且每帧大小在创建时是固定的——“帧”包含了一定数量的寄存器值（取决于当前的具体函数）以及执行函数时所需的额外信息，比如程序计数器等。

（2）指令的存储单位采用的是16bit的无符号数。

（3）Strings、types、fields及methods有各自独立的索引常量值（Constant Pools），这点和Java规范中的字节码是类似的。

（4）从经验来看，一个函数所需的寄存器数量大致在8～16个，所以很多指令都被限制只能访问16个寄存器（不过这并不是绝对的，Dalvik理论上可以访问的虚拟寄存器数量可以达到65536）。

（5）有一些“伪指令”被用于承载不定长度的数据，这些指令在常规执行流中是不应该出现的。同时，它们需要做到4字节对齐。为了达到这一目标，在某些情况下需要我们添加额外的nop指令。

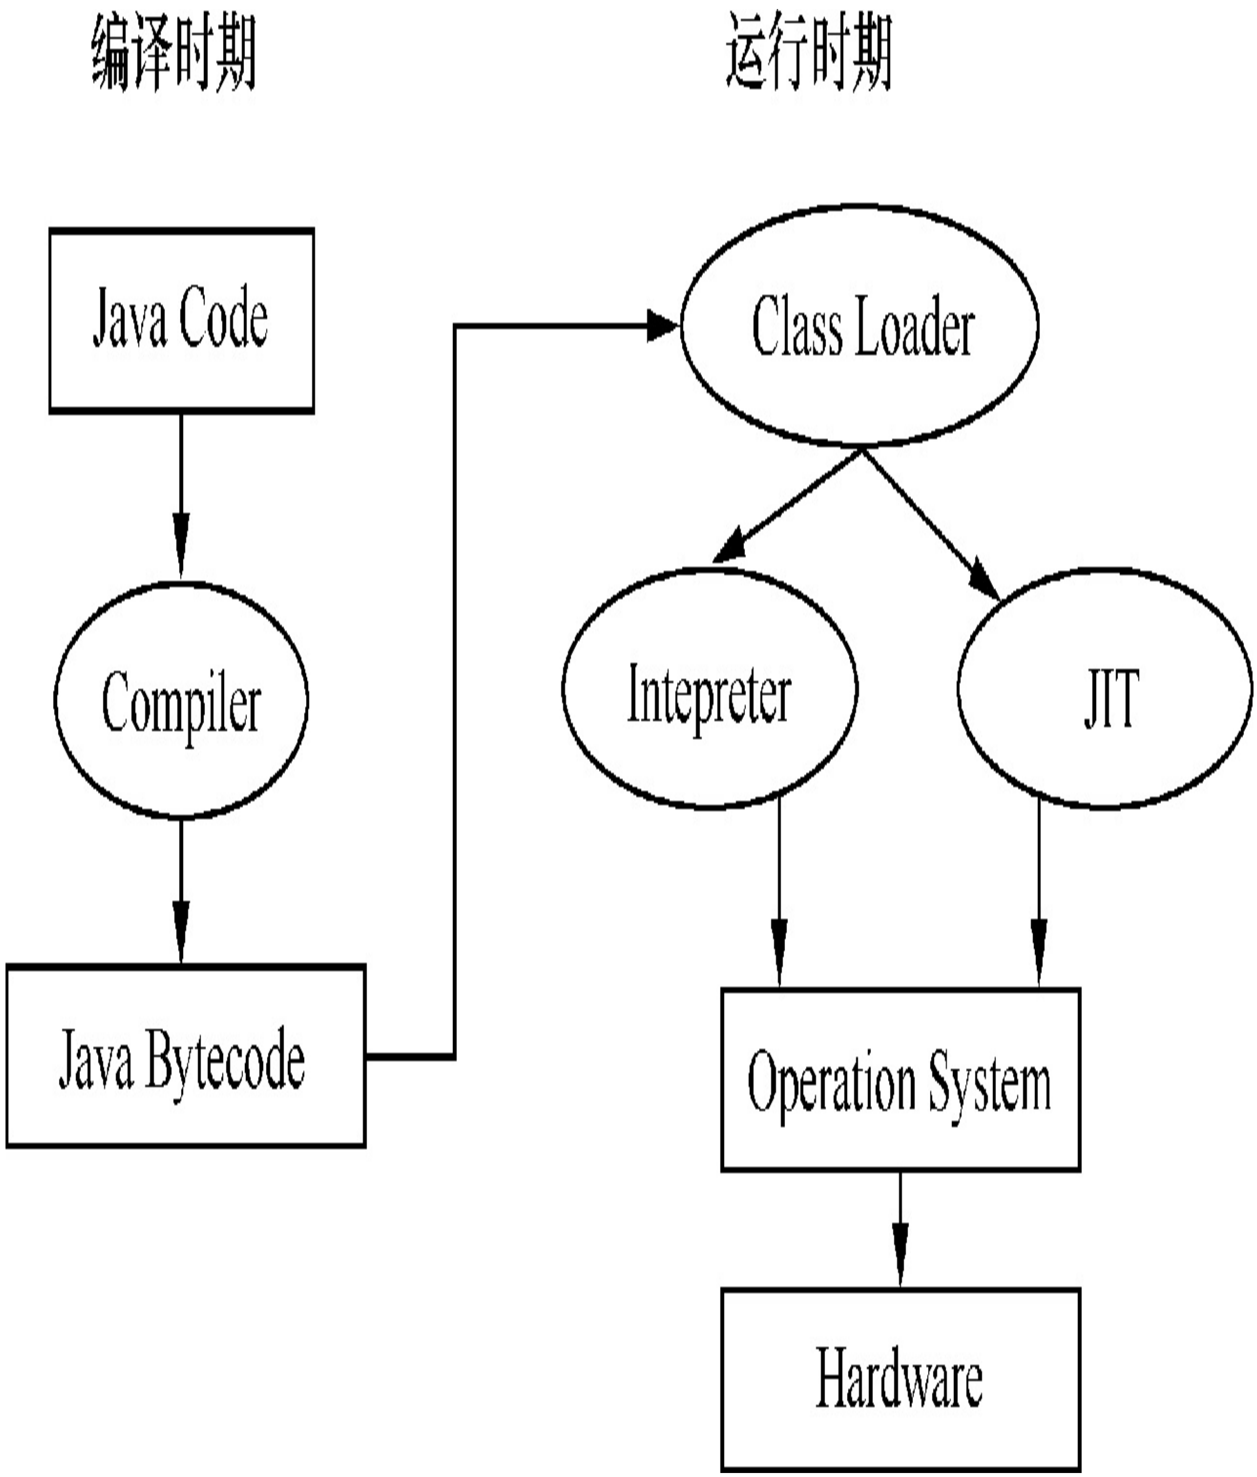

▲图21-18　Java编译和运行时简图

表21-3是对Android中常用字节码的释义，供大家参考学习。

表21-3　　Android虚拟机常用字节码释义

Op&Format	Mnemonic/Syntax	Arguments	Description
00 10x	nop		空操作
01 12x	move vA, vB	A:目标寄存器（4bits）B:源寄存器（4bits）	将源寄存器的内容转移到目标寄存器中
02 22x	move/from16 vAA, vBBBB	A:目标寄存器（8bits）B:源寄存器（8bits）	同上
03 32x	move/16 vAAAA, vBBBB	A:目标寄存器（16bits）B:源寄存器（16bits）	同上
11 11x	return-object vAA	A:返回值寄存器	从一个需要返回值的函数中返回
27 11x	throw vAA	A:exception-bearing寄存	抛出指定的异常事

		器（8bits）	件
28 10t	goto +AA	A:分支的偏移量	无条件跳转到指定地址
32..37 22t	if-*test* vA, vB, +CCCC 32: if-eq 33: if-ne 34: if-lt 35: if-ge 36: if-gt 37: if-le	A: 参与测试的寄存器1（4 bits） B: 参与测试的寄存器2（4 bits） C: 分支偏移量（16 bits）	如果两个寄存器的测试结果符合要求（比如是否相等、大于、等于），则跳转到指定地址

另外，Android编译Java的过程也与JDK中的处理方式存在差异。它首先会将Java代码编译成.class文件，然后再利用Android系统提供的dx工具将其进一步转换为.dex。换言之Android系统并没有直接使用.class文件——那么Dex与JDK标准的Class格式文件相比有什么区别呢？如图21-19所示。

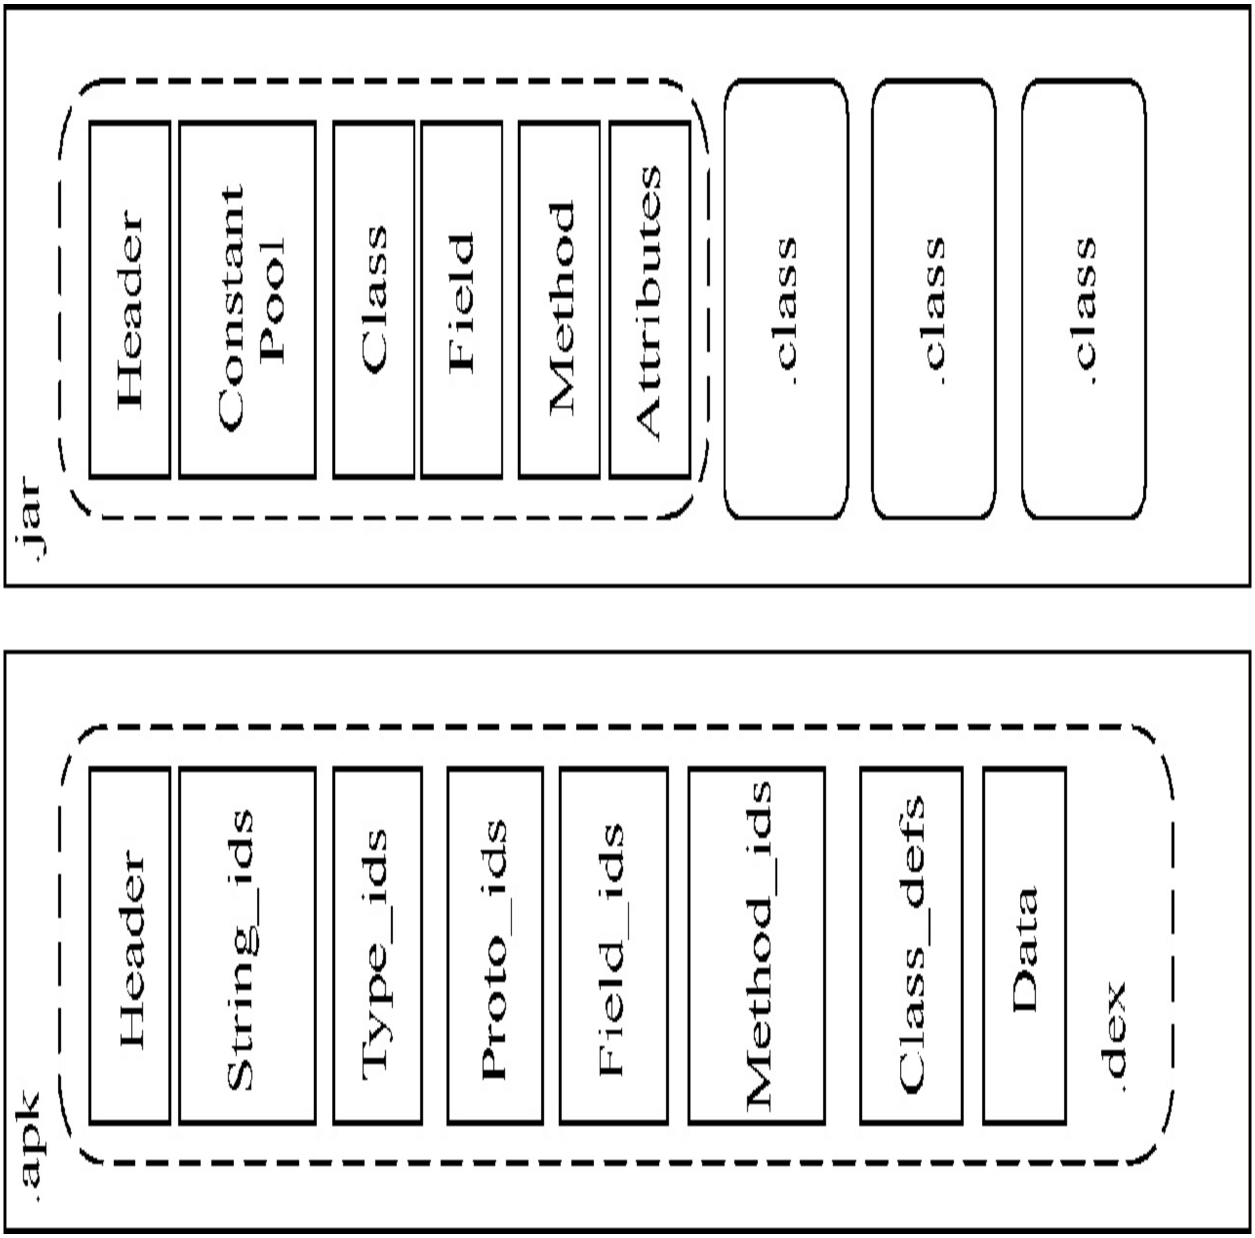

▲图21-19　Dex文件格式与Class文件格式的对比

关于Class文件格式的详细介绍信息，大家可以查阅Oracle的官方文档，网址如下：

http://docs.oracle.com/javase/specs/

由图21-19可知，一个Android应用程序中通常只包含一个Dex文件（注意：这并不是绝对的，譬如在函数数量超过限制时Dex需要做分包处理）。这和标准Java规范中的做法是不一样的，后者会在一个Jar包

中存储若干个Class文件，并分别管理。这就意味着Dx工具需要对各Class进行统一处理，然后将内容“糅合”进最终的Dex文件中。

Dex文件中的各主要域的释义如表21-4所示。

表21-4　主要域

Name	Format	Description
header	header_item	文件头
string_ids	string_id_item[]	本Dex文件中所使用的字符串列表，不允许有重复项
type_ids	type_id_item[]	本Dex文件中所使用的数据类型列表，不允许有重复项
proto_ids	proto_id_item[]	函数原型列表，不允许有重复项
field_ids	field_id_item[]	本Dex文件中所引用的各种域（field）的列表，不允许有重复项
method_ids	method_id_item[]	本Dex文件中所引用的所有函数的列表，不允许有重复项
class_defs	class_def_item[]	类定义列表。父类（superclass）、接口（interface）在列表中的位置需要比子类靠前

data	ubyte[]	用于支撑上述所有列表的相关数据
link_data	ubyte[]	链接文件所使用的数据

下面我们通过解析一个具体的Dex文件来加深大家的理解。

（1）范例源码是由两个类组成的，如下所示：

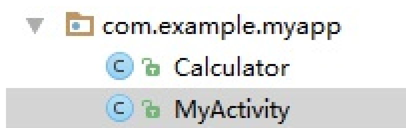

（2）其中MyActivity中的实现如下：

```
package com.example.myapp;

import android.app.Activity;
import android.os.Bundle;

public class MyActivity extends Activity {
    @Override
    public void onCreate(Bundle savedInstanceState) {
        super.onCreate(savedInstanceState);
        setContentView(R.layout.main);
        Calculator cal = new Calculator();
        System.out.println("add="+cal.add());
    }
}
```

（3）Calculator的实现如下：

```
package com.example.myapp;

public class Calculator {
     public int add()
     {
        int a=400;
        int b=200;
        int c= a+b;
        return c;
     }
```

```
}
```

我们按照常规的Android应用程序编译流程来生成最终的APK文件，然后再从后者中提取出classes.dex文件。紧接着我们利用Android官方提供的dexdump工具来解析它的内部构造，命令如下：

```
dexdump -f classes.dex >example
```

我们从上述命令的输出结果中截取部分内容，如下所示：

```
Processing 'classes.dex'...
Opened 'classes.dex', DEX version '035'
DEX file header:
magic               : 'dex\n035\0'
checksum            : 05378d39
signature           : 6927...8403
file_size           : 2700
header_size         : 112
link_size           : 0
link_off            : 0 (0x000000)
string_ids_size     : 56
string_ids_off      : 112 (0x000070)
type_ids_size       : 21
type_ids_off        : 336 (0x000150)
proto_ids_size      : 8
proto_ids_off       : 420 (0x0001a4)
field_ids_size      : 5
field_ids_off       : 516 (0x000204)
method_ids_size     : 19
method_ids_off      : 556 (0x00022c)
class_defs_size     : 8
class_defs_off      : 708 (0x0002c4)
data_size           : 1736
data_off            : 964 (0x0003c4)
```

Dex的文件头记录的是Magic数（“dex\n035\0”）、校验码、签名、总文件大小、各个区段所占的空间大小以及它们的起始地址在本文件中的偏移量等一系列信息。

接下来我们以strings_ids和method_ids为例，讲解如何读取Dex中的这些字段数据。

（1）string_ids

上述dump结果中显示的string_ids_off值为112（0x70）。细心的读者一定注意到了，文件头所占的大小亦是112——意味着String这一区段是紧挨着Header存储的。0x70处的数据如下所示：

```
00000070h: A6 05 00 00 AE 05 00 00 C0 05 00 00 D1 05 00 00
```

由string_ids_size我们知道，String_ids所包含的项目总数是56，而且每一个item都遵循string_id_item数据结构（Dex文件格式相关的所有数据结构都可以在Android官网上找到详细释义：https://source.android.com/devices/tech/dalvik/dex-format.html），如图21-20所示。

string_id_item

appears in the string_ids section

alignment: 4 bytes

Name	Format	Description
string_data_off	uint	offset from the start of the file to the string data for this item. The offset should be to a location in the data section, and the data should be in the format specified by "string_data_item" below. There is no alignment requirement for the offset.

▲图21-20　Dex文件的格式

每一个string_id_item所占的空间大小也是固定的，为4Byte，并且按照高位在后的顺序进行存储。以Calculator场景中String_ids的第一项“0xA605 0000”为例，它实际对应的值就是“0x0000 05A6”。这个地址指示的是用于描述该String具体数据的string_data_item在Dex文件中的偏移量，如下所示：

```
000005a0h: 01 00 00 00 02 00 06 3C 69 6E 69 74 3E 00 10 42 ; .......<init>..B
```

String_data_item也是一个固定的数据结构，如图21-21所示。

string_data_item

appears in the data section

alignment: none (byte-aligned)

Name	Format	Description
utf16_size	uleb128	size of this string, in UTF-16 code units (which is the "string length" in many systems). That is, this is the decoded length of the string. (The encoded length is implied by the position of the `0` byte.)
data	ubyte[]	a series of MUTF-8 code units (a.k.a. octets, a.k.a. bytes) followed by a byte of value `0`. See "MUTF-8 (Modified UTF-8) Encoding" above for details and discussion about the data format. **Note:** It is acceptable to have a string which includes (the encoded form of) UTF-16 surrogate code units (that is, `U+d800` ... `U+dfff`) either in isolation or out-of-order with respect to the usual encoding of Unicode into UTF-16. It is up to higher-level uses of strings to reject such invalid encodings, if appropriate.

▲图21-21　string_data_item数据结构解析

对照string_data_item的数据格式，不难得出0x05A6这个地址所表示的字符串大小为6，具体指的是“<init>”这个函数名。

（2）method_ids

Method和String的处理过程也是类似的，只不过面对的数据结构有所区别。

Method_ids是一个method_id_item[]数组，后者对应的数据结构如图21-22所示。

method_id_item

appears in the method_ids section

alignment: 4 bytes

Name	Format	Description
class_idx	ushort	index into the `type_ids` list for the definer of this method. This must be a class or array type, and not a primitive type.
proto_idx	ushort	index into the `proto_ids` list for the prototype of this method
name_idx	uint	index into the `string_ids` list for the name of this method. The string must conform to the syntax for *MemberName*, defined above.

▲图21-22　method_id_item数据结构解析

每一个method_id_item占用4个字节空间。在Calculator这个范例中，method_ids的偏移地址是556（0x00022c），我们截取部分数据显示如图21-23所示。

```
00000220h: 24 00 00 00 12 00 0E 00 30 00 00 00 01 00 04 00
00000230h: 00 00 00 00 01 00 06 00 2F 00 00 00 03 00 04 00
00000240h: 00 00 00 00 04 00 04 00 00 00 00 00 04 00 00 00
00000250h: 22 00 00 00 05 00 04 00 00 00 00 00 05 00 06 00
```

▲图21-23　数据

我们随机选取第4个函数来分析，对应的数据是“0x0400 0000 2200 0000”。其中class_idx（此函数所属的Class）的值是0x04，即type_ids数组的第4项；proto_idx（此函数的原型）的值是“0x00”，即proto_ids的第0项；最后，name_idx（此函数的名称）指向的是string_ids的第0x22项，由前述的讲解不难推算出具体值是“add”。

那么函数的具体实现保存在哪个区域呢？

答案是class_defs。具体而言，class_defs是由class_def_item[]组成的。而class_def_item数据结构中又有一个class_data_off偏移量指向class_data_item——这个地方用于集中保存Class内部的各种函数和域。

在Android虚拟机规范中，函数会被细分为Virtual、Direct、

Super等多种类型，而且调用这些函数所使用的字节码指令也是不同的。如表21-5所示。

表21-5　Android虚拟机中的函数种类及调用指令

Type	Bytecode	Description
Virtual	6e: invoke-virtual	这是最常见的函数类型。之所以冠之以“Virtual”，是因为这类函数是可以被重载的。换句话说，除了private、static和final（还有构造函数）等之外的函数通常都属于virtual类型。处理这类函数时需要特别考虑VTable的实现，所以在执行效率上相对于其他函数类型会稍微低一些
Super	6f: invoke-super	即Superclass的Virtual Method
Direct	70: invoke-direct	不能被重载的非静态函数
Static	71: invoke-static	静态函数
Interface	72: invoke-interface	接口函数

以“add”函数为例，它编译生成的字节码如下：

```
  Virtual methods   -
    #0              : (in Lcom/example/myapp/Calculator;)
      name          : 'add'
      type          : '()I'
      access        : 0x0001 (PUBLIC)
      code          -
      registers     : 4
      ins           : 1
      outs          : 0
      insns size    : 7 16-bit code units
00042c:                                   |[00042c] com.example.myapp
00043c: 1300 9001                         |0000: const/16 v0, #int 40
000440: 1301 c800                         |0002: const/16 v1, #int 20
000444: 9002 0001                         |0004: add-int v2, v0, v1
000448: 0f02                              |0006: return v2
```

同时onCreate中调用add函数对应的字节码实现如下：

```
0004a8: 6e10 0400 0000          |001a: invoke-virtual {v0},
                                Lcom/example/myapp/Calculator;.add:
0004ae: 0a03                    |001d: move-result v3 ###将函数返回值
```

因为add函数属于Calculator这个类，所以invoke-virtual中的参数是Lcom/example/myapp /Calculator。

为了支持多态性，虚拟机会为类（有需要的情况下）提供两个特殊的表，即VTable和ITable。

下面是一个简单的范例：

```
class A
{
     public void Method1(){
     }
     public void Method2(String a){
     }
}

Class B extends A{
     public  void Method1(){
     }
     public void Method3(){
       Method1();
```

```
    }
}
```

子类在构建自己的VTable时，首先会完整复制父类的VTable，然后再以此为基础替换生成自己的虚拟函数表。在上面这个例子中，Class A的虚拟表是：

A.Method1

A.Method2

因为Class B继承自Class A，并且重载了Method1，所以它的VTable就变为：

B.Method1

A.Method2

B.Method3

这样一来，B.Method3()在运行阶段通过上述虚拟表就可以查出其所调用的Method1对应的最终函数是B.Method1；而假如Class B没有重载Method1，那么它的VTable中第1个函数就仍然是A.Method1，从而产生不一样的效果。

那么ITable又是什么呢，为什么除了VTable外还需要一个ITable？我们知道，Java语言中虽然只允许继承一个父类，但却可以实现多个接口。换句话说，VTable并没有办法解决所有的多态问题，因而虚拟机又引入了ITable来处理这种情况。我们在后续小节分析Art的内部实现时还有针对ITable的更多讲解，建议大家结合起来阅读。

21.3　Android虚拟机核心文件格式——可执行文件的基石ELF

Android对于Linux的借鉴并不仅仅体现在操作系统层面，在很多技术实现上也是如此。以Android M版本中的Art虚拟机为例，其最大的特点就是通过dex2oat将Dex预编译成包含了机器指令的oat文件，从而显著提升了程序的执行效率。而oat文件本身并不是一个新事物，它是Android系统基于Linux中的可执行文件格式——ELF所做的扩展。Android系统既遵循了ELF文件协议，同时还根据Art虚拟机的特点和具体需求“另辟蹊径”，针对ELF做了巧妙的扩展，可谓是“鱼和熊掌兼得”。

本小节中我们将讲解ELF的基础知识，从而为大家后续学习oat和程序的执行过程扫清障碍。如果读者对ELF已经有深入了解，那么可以选择跳过本小节内容。

21.3.1　ELF文件格式

Executable and Linkable Format（ELF），最初是由UNIX系统实验室作为《Application Binary Interface Specification》的一个核心组成元素发布的（可以参考阅读https://refspecs.linuxfoundation.org/elf/gabi41.pdf），随后又被整合到《Tool Interface Standard（TIS）Portable Formats Specification》规范中。TIS在1993年和1995年分别发布了v1.1和v1.2两个版本的ELF规范。建议读者可以在本小节的基础上再自行查阅1.2版本，以便对ELF有更全面的认识。下面是Linux基金会提供的ELF规范的下载地址：

```
https://refspecs.linuxfoundation.org/elf/elf.pdf
```

另外，TIS和ABI中所包含的ELF规范是通用性质的，各芯片处理器厂商还会在此基础上融入与Processor相关的具体信息。这种可扩展性也是ELF得以广泛推广的一个重要原因，我们后续在分析它的内部结构还会有进一步讲解。

从ELF文件的典型处理过程来看，它至少支持3种文件形态，分别是可重定向文件（Relocatable File）、可执行文件（Executable File）和可共享的对象文件（Shared Object File）。如图21-24所示。

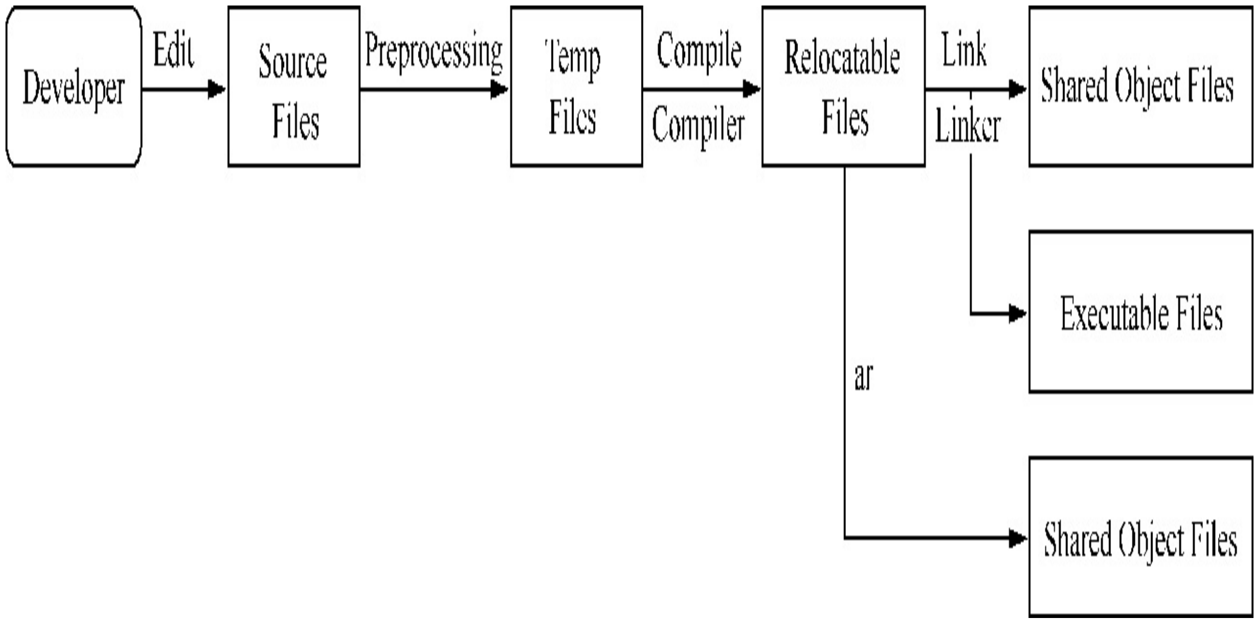

▲图21-24　ELF的典型处理流程

首先，开发人员利用IDE或者文本编辑器编写源码文件（如C/C++语言源代码）。预处理主要针对的是各种预编译语句，如“#define”“#include”等，并将处理结果输出给编译阶段。紧接着的编译任务涉及的环节比较多，包括语法分析、语义分析和优化等，因而通常也是最耗时的。不过它的产出物还不是最终的机器码，而是汇编码——这也就是下一步我们需要执行Assembly的原因，此时得到的文件我们称为目标文件（Object File）。一个可执行对象（或者库）通常是由多个Object组成的，所以我们还需要最后一步，即通过Linking（这个过程中会涉及Address Allocation、Symbol Resolution、Relocation重定位等多个过程）生成为最终的输出物（如动态链接库、可执行文件等），或者利用ar来生成静态库。当然，现在的编译器一般会把这些步骤隐藏起来，用户只需要利用简单的命令就可以完成所有编译链接过程了。

Relocatable File的一个具体范例是.o文件，它是在编译过程中产生的“中间文件”。例如图21-25所示的是AOSP工程中adbd程序的编译产物，其中包含了很多.o文件：

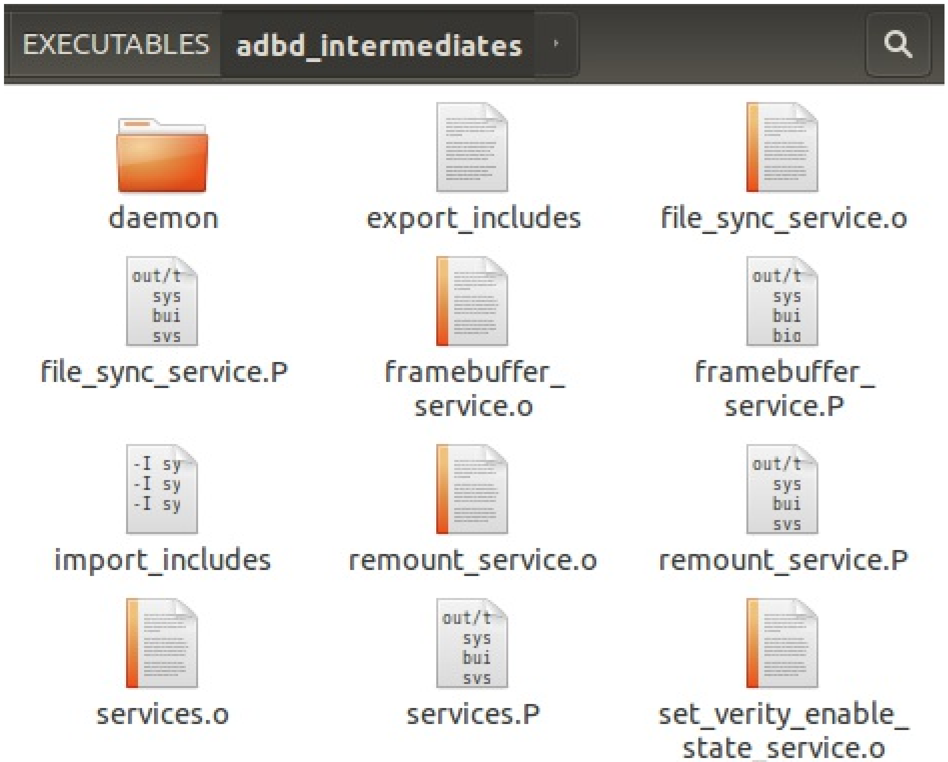

▲图21-25 adbd程序的编译产物

我们可以通过file命令来揭开这些.o文件的“庐山真面目”：

```
s@ubuntu:~/Android_M/out/target/product/generic/obj/EXECUTABLES/adbd_intermediates$ file services.o file_sync_service.o framebuffer_service.o
mount_service.o set_verity_enable_state_service.o
services.o:                        ELF 32-bit LSB  relocatable, ARM, EABI5 version 1 (GNU/Linux), not stripped
file_sync_service.o:               ELF 32-bit LSB  relocatable, ARM, EABI5 version 1 (GNU/Linux), not stripped
framebuffer_service.o:             ELF 32-bit LSB  relocatable, ARM, EABI5 version 1 (GNU/Linux), not stripped
remount_service.o:                 ELF 32-bit LSB  relocatable, ARM, EABI5 version 1 (GNU/Linux), not stripped
set_verity_enable_state_service.o: ELF 32-bit LSB  relocatable, ARM, EABI5 version 1 (GNU/Linux), not stripped
```

可见它们都属于ELF（32bit或64bit） Relocatable文件。

除了上述的“中间文件”外，ELF格式的可执行文件相信大家也不会陌生。Linux平台下的大部分可执行程序都采用了ELF规范，Android系统自然也不例外。例如下面所示的是针对Android工程中prebuilt/qemu-kernel/arm目录下的vmlinux-qemu程序执行的file结果：

```
s@ubuntu:~/Android_M/prebuilts/qemu-kernel/arm$ file vmlinux-qemu
vmlinux-qemu: ELF 32-bit LSB  executable, ARM, EABI5 version 1 (SYSV), statically linked, BuildID[sha1]=8887e22689309b389959c29fd3ea9d942c94b80b
, not stripped
```

可见它们的文件格式是ELF（32bit或者64bit）Executable。

ELF的另一种文件形态是Shared Object File（即动态链接库），通常情况下以“.so”为后缀名。Android工程中同样包含了很多动态链接库对象，例如下面所示的libselinux.so：

```
s@ubuntu:~/Android_M/out/host/linux-x86/lib64$ file libselinux.so
libselinux.so: ELF 64-bit LSB  shared object, x86-64, version 1 (SYSV), dynamically linked, BuildID[sha1]=a427918cf96ef98f7ea3e6577cf648673e0190
16, not stripped
```

由此可见，ELF文件规范实际上就贯穿于整个Android工程中。

有了这些“感性”的认识后，接下来我们进一步了解ELF文件格式的内部构成。

根据ELF规范文档中的描述，我们可以从Linking和Execution两个视角来审视它的内部结构，如图21-26所示。

那么ELF的设计者为什么要为它提供两个不同的视角，图21-26所示的Section和Segment之间的区别和联系又是什么呢？

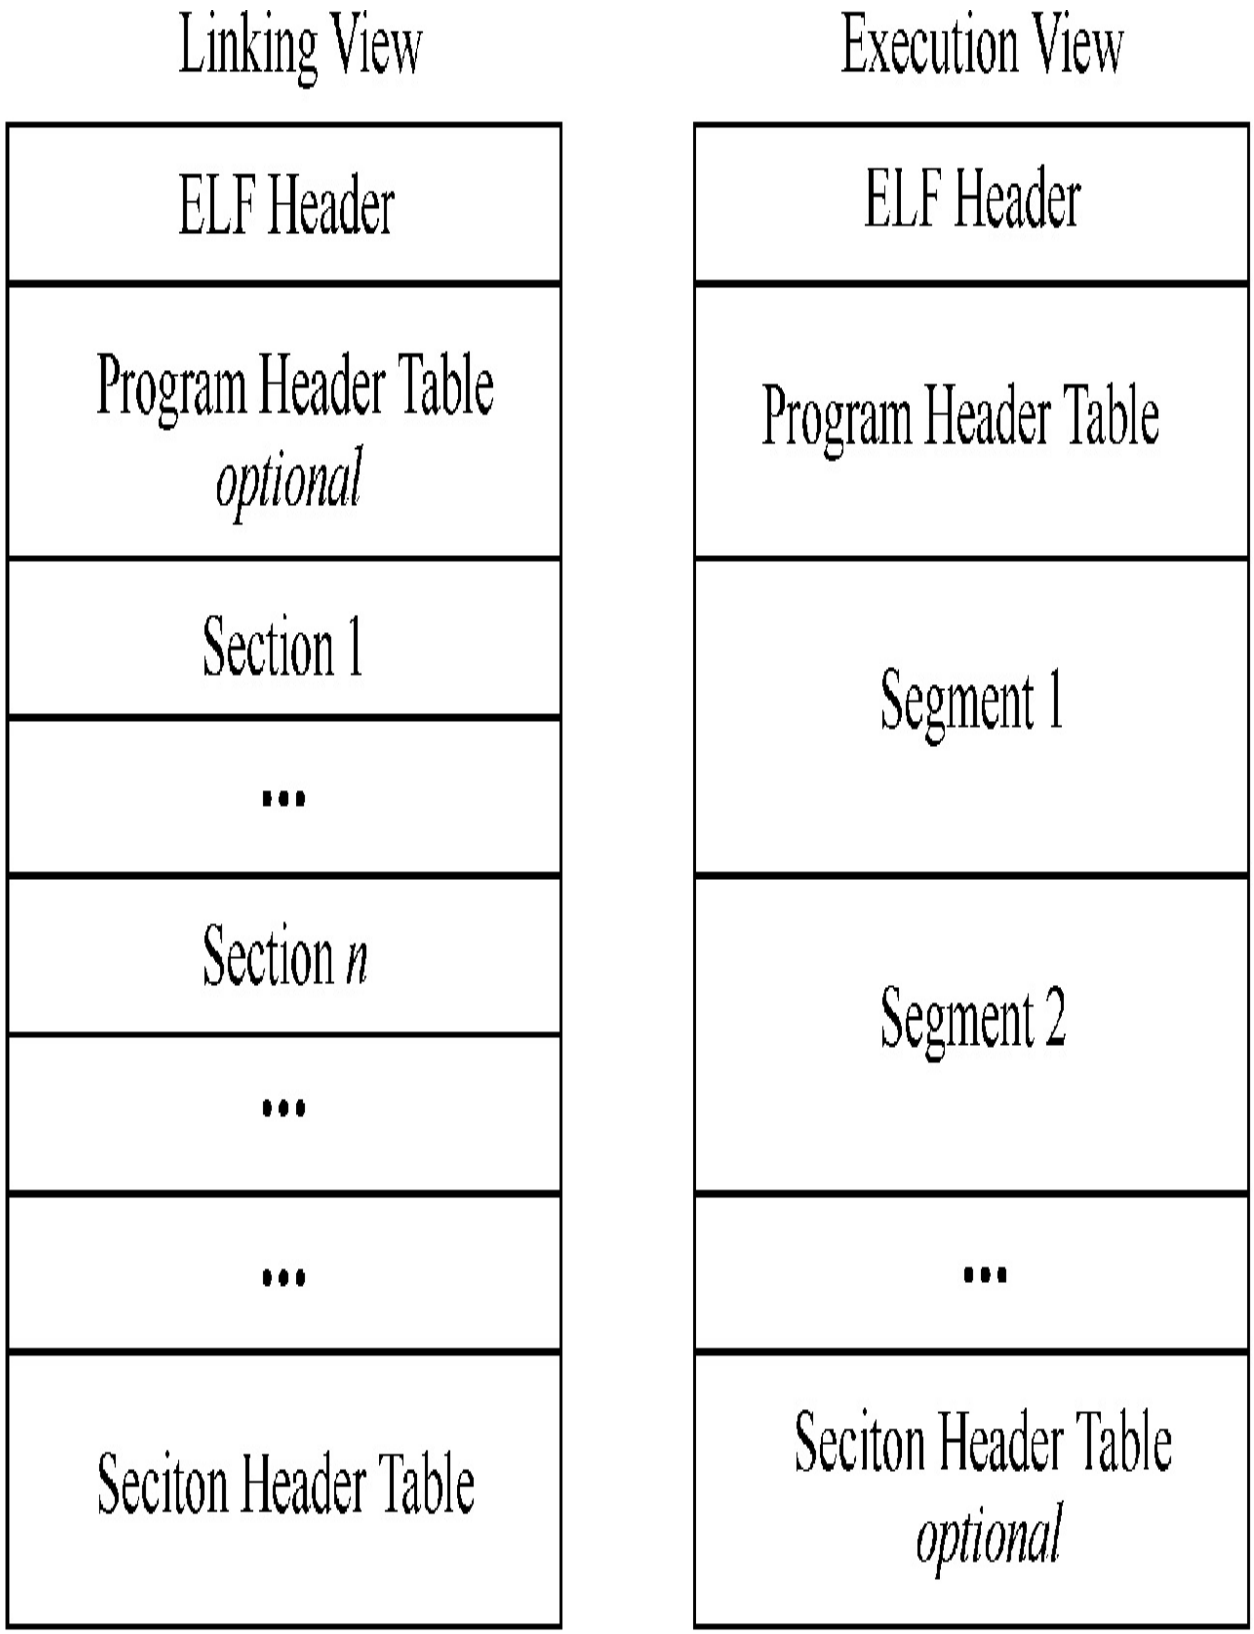
Linking View
ELF Header
Program Header Table
optional
Section 1
...
Section *n*
...
...
Seciton Header Table
Execution View
ELF Header
Program Header Table
Segment 1
Segment 2
...
Seciton Header Table
optional

OSD1980

▲图21-26 ELF文件格式的两个视角

简单来讲，Section中存储的信息用于支撑程序的链接工作，针对的是Linker；而Segment提供的则是程序运行时所需的数据，面向的是加载器Loader。另外，以Segment的方式加载在一定程度上还可以节约存储空间。这是因为Section在加载时是页对齐的，这样难免会造成空间资源的浪费。而一个Segment由多个段组成，段与段之间没有间隔，所以能尽量避免类似情况的发生。由于Section和Segment的中文译名都可以是“段”，大家在查阅相关资料时一定要鉴别清楚作者所指的是什么，以免“一头雾水，事倍功半”。

接下来我们编写一个简单的程序，并通过解析这个程序的内部构造来帮助大家更好地理解ELF文件格式。

范例程序的功能相当简单，就是完成对两个int变量的求和操作，如下所示：

```
/*main.c*/
#include "stdio.h"

void main()
{
     add(1,2);
     printf("This is an example");
}

int add(int value1, int value2)
{
     return value1+value2;
}
```

我们首先通过gcc将上述的main.c编译成main.o文件，命令行如下：

```
gcc  –c  main.c
```

然后利用readelf读取它的头文件内容，结果如图21-27所示。

```
s@ubuntu:~/TestELF$ readelf -h main.o
ELF Header:
  Magic:   7f 45 4c 46 02 01 01 00 00 00 00 00 00 00 00 00
  Class:                             ELF64
  Data:                              2's complement, little endian
  Version:                           1 (current)
  OS/ABI:                            UNIX - System V
  ABI Version:                       0
  Type:                              REL (Relocatable file)
  Machine:                           Advanced Micro Devices X86-64
  Version:                           0x1
  Entry point address:               0x0
  Start of program headers:          0 (bytes into file)
  Start of section headers:          384 (bytes into file)
  Flags:                             0x0
  Size of this header:               64 (bytes)
  Size of program headers:           0 (bytes)
  Number of program headers:         0
  Size of section headers:           64 (bytes)
  Number of section headers:         13
  Section header string table index: 10
```

▲图21-27　ELF的Header信息

顺便说一下，readelf是Linux系统中分析ELF文件的一个很方便的工具。大家可以通过“--help”命令来获取到它的具体使用方法。

根据ELF官方文档的描述，ELF Header对应的数据结构是：

```
#define EI_NIDENT       16

typedef struct {
        unsigned char  e_ident[EI_NIDENT];
        Elf32_Half     e_type;
        Elf32_Half     e_machine;
        Elf32_Word     e_version;
        Elf32_Addr     e_entry;
        Elf32_Off      e_phoff;
        Elf32_Off      e_shoff;
        Elf32_Word     e_flags;
        Elf32_Half     e_ehsize;
        Elf32_Half     e_phentsize;
        Elf32_Half     e_phnum;
        Elf32_Half     e_shentsize;
        Elf32_Half     e_shnum;
        Elf32_Half     e_shstrndx;
 } Elf32_Ehdr;
```

我们对照上面readelf得到的实例数据，来逐一解释Elf32_Ehdr中各个字段的含义（注意：readelf对ELF文件进行了“可读性”处理，因而在显示顺序上有可能和上述的数据结构没有完全一致）：

- EI_NIDENT

由readelf的结果可以看到，ELF的Magic区域共16个字节，即“7f 45 4c 46 02 01 01 00 00 00 00 00 00 00 00 00”。好比每种商品都需要一个标签一样，ELF也需要一张“身份证”：前4个字节“7f 45 4c 46”表示ELF的文件魔数，即ASCII码“.ELF”；第5个字节代表硬件平台的位数（1代表32位，2代表64位）;第6个字节表示数据的大小端模式（1代表小端模式，2代表大端模式）；第7个字节代表ELF的版本号，不过到目前为止这个数只能被置为1；第8个字节用于表示目标操作系统ABI（例如0x00表示System V，0x01表示HP-UX，0x02表示NetBSD，0x03表示Linux等）。

- 紧随其后的e_type用于指示这个ELF对象的文件类型。核心值如下

所示：

Name	Value	Meaning
ET_NONE	0	No file type
ET_REL	1	Relocatable file
ET_EXEC	2	Executable file
ET_DYN	3	Shared object file
ET_CORE	4	Core file
ET_LOPROC	0xff00	Processor-specific
ET_HIPROC	0xffff	Processor-specific

例如编译阶段得到的.o可重定位文件，就属于ET_REL类型。

- e_machine

用于标记机器的平台架构，可选值如下所示：

Name	Value	Meaning
EM_NONE	0	No machine
EM_M32	1	AT&T WE 32100
EM_SPARC	2	SPARC
EM_386	3	Intel 80386
EM_68K	4	Motorola 68000
EM_88K	5	Motorola 88000
EM_860	7	Intel 80860
EM_MIPS	8	MIPS RS3000

- e_version

用于指示ELF规范的版本号。

- e_entry

程序的入口地址，即系统将首先把控制权传递到e_entry这个虚地址所指示的位置。在我们这个main.o范例中e_entry的具体值为0。

- e_phoff

用于指示Program Header Table在这个ELF文件中的偏移量（以字节为单位），在我们这个场景下e_phoff为0。

- e_shoff

用于指示Section Header Table在这个ELF文件中的偏移量（以字节为单位），有可能为0。我们会在后续内容中做进一步分析。

- e_flags

这是与本ELF文件所针对的目标处理器相关（Processor-Specific）的标志位。图21-28所示是《ELF for the Arm Architecture》中关于e_flags的描述。

Table 4-2, ARM-specific e_flags

Value	Meaning
EF_ARM_ABIMASK (0xFF000000) (current version is 0x05000000)	This masks an 8-bit version number, the version of the ABI to which this ELF file conforms. This ABI is version 5. A value of 0 denotes unknown conformance.
EF_ARM_BE8 (0x00800000)	The ELF file contains BE-8 code, suitable for execution on an ARM Architecture v6 processor. This flag must only be set on an executable file.
EF_ARM_GCCMASK (0x00400FFF)	Legacy code (ABI version 4 and earlier) generated by gcc-arm-xxx might use these bits.
EF_ARM_ABI_FLOAT_HARD (0x00000400) (ABI version 5 and later)	Set in executable file headers (e_type = ET_EXEC or ET_DYN) to note that the executable file was built to conform to the hardware floating-point procedure-call standard. Compatible with legacy (pre version 5) gcc use as EF_ARM_VFP_FLOAT.
EF_ARM_ABI_FLOAT_SOFT (0x00000200) (ABI version 5 and later)	Set in executable file headers (e_type = ET_EXEC or ET_DYN) to note *explicitly* that the executable file was built to conform to the software floating-point procedure-call standard (the *base standard*). If both EF_ARM_ABI_FLOAT_XXXX bits are clear, conformance to the base procedure-call standard is implied. Compatible with legacy (pre version 5) gcc use as EF_ARM_SOFT_FLOAT.

▲图21-28　e_flags的描述

- e_ehsize

　　用于描述ELF Header所占的空间大小（以字节为单位）。

- e_phentsize

　　用于标记一个Program Header所占的空间大小（以字节为单位），有可能为0。因为我们的范例是编译产生的中间.o文件，所以并不涉及Segment。

- e_phnum

　　用于标记Program Header Table的总条目数，有可能为0。

- e_shentsize

　　用于标记一个Section Header所占的空间大小（以字节为单位）。

- e_shnum

　　用于标记Section Header Table的总条目数。

　　前面我们提到，Section主要是在链接和重定位阶段发挥作用。换句话说，Relocable Files正常情况下都会包含Section信息。我们同样可以利用readelf工具把ELF中的Section信息打印出来，所用命令行如下：

```
readelf  -S  main.o
```

　　根据图21-29所示的输出结果，可以得知main.o包含了多达13个的Section，其中既有大家所熟悉的.text（程序代码），.data（已赋初始值的静态变量）和.bss段（未赋初始值的全局变量和静态变量），也有.rela.text、.symtab这类看上去比较陌生的Section——那么后面这些段有什么作用呢？

　　简单来说，它们将在程序链接、重定位或者其他环节中起到辅助作用。譬如.shstrtab是“Section Header String Table”的缩写，用于

记录每个Section的名称。它在main.o中的偏移地址为0x118（图21-29中的“Offset”列），占用空间大小为0x61。我们可以利用下面的命令来分析.shstrtab中存储的内容是什么：

```
hexdump  -C main.o
```

结果值如图21-30所示。

```
Section Headers:
  [Nr] Name              Type             Address           Offset
       Size              EntSize          Flags  Link  Info  Align
  [ 0]                   NULL             0000000000000000  00000000
       0000000000000000  0000000000000000           0     0     0
  [ 1] .text             PROGBITS         0000000000000000  00000040
       000000000000003d  0000000000000000  AX       0     0     1
  [ 2] .rela.text        RELA             0000000000000000  000005f8
       0000000000000048  0000000000000018          11     1     8
  [ 3] .data             PROGBITS         0000000000000000  0000007d
       0000000000000000  0000000000000000  WA       0     0     1
  [ 4] .bss              NOBITS           0000000000000000  0000007d
       0000000000000000  0000000000000000  WA       0     0     1
  [ 5] .rodata           PROGBITS         0000000000000000  0000007d
       0000000000000013  0000000000000000   A       0     0     1
  [ 6] .comment          PROGBITS         0000000000000000  00000090
       000000000000002c  0000000000000001  MS       0     0     1
  [ 7] .note.GNU-stack   PROGBITS         0000000000000000  000000bc
       0000000000000000  0000000000000000           0     0     1
  [ 8] .eh_frame         PROGBITS         0000000000000000  000000c0
       0000000000000058  0000000000000000   A       0     0     8
  [ 9] .rela.eh_frame    RELA             0000000000000000  00000640
       0000000000000030  0000000000000018          11     8     8
  [10] .shstrtab         STRTAB           0000000000000000  00000118
       0000000000000061  0000000000000000           0     0     1
  [11] .symtab           SYMTAB           0000000000000000  000004c0
       0000000000000120  0000000000000018          12     9     8
  [12] .strtab           STRTAB           0000000000000000  000005e0
       0000000000000018  0000000000000000           0     0     1
```

▲图21-29　ELF中的Section范例

```
00000110  06 4f 0c 07 08 00 00 00  00 2e 73 79 6d 74 61 62  |.O.......symtab|
00000120  00 2e 73 74 72 74 61 62  00 2e 73 68 73 74 72 74  |..strtab..shstrt|
00000130  61 62 00 2e 72 65 6c 61  2e 74 65 78 74 00 2e 64  |ab..rela.text..d|
00000140  61 74 61 00 2e 62 73 73  00 2e 72 6f 64 61 74 61  |ata..bss..rodata|
00000150  00 2e 63 6f 6d 6d 65 6e  74 00 2e 6e 6f 74 65 2e  |..comment..note.|
00000160  47 4e 55 2d 73 74 61 63  6b 00 2e 72 65 6c 61 2e  |GNU-stack..rela.|
00000170  65 68 5f 66 72 61 6d 65  00 00 00 00 00 00 00 00  |eh_frame........|
```

▲图21-30　shstrtab section中的内容

这和我们在“readelf　-S”看到的情况是一致的。

“.strtab”是“String Table”的简写，是字符串的列表集合。每个字符串都被要求以ASCII格式存储，且以“\0”结尾：

```
000005e0  00 6d 61 69 6e 2e 63 00  6d 61 69 6e 00 61 64 64  |.main.c.main.add
000005f0  00 70 72 69 6e 74 66 00  14 00 00 00 00 00 00 00  |.printf.........
```

那么各个Symbol是如何与.strtab对应起来的呢？这就是.symtab所起的作用，它为每个Symbol都分配了一个全局唯一的entry，从而建立起符号与字符串之间的对应关系。以main.c中的add函数（Symbol）为例，其在.symtab中对应的是如图21-31所示的第10项内容。

```
Symbol table '.symtab' contains 12 entries:
   Num:    Value          Size Type    Bind   Vis      Ndx Name
     0: 0000000000000000     0 NOTYPE  LOCAL  DEFAULT  UND
     1: 0000000000000000     0 FILE    LOCAL  DEFAULT  ABS main.c
     2: 0000000000000000     0 SECTION LOCAL  DEFAULT    1
     3: 0000000000000000     0 SECTION LOCAL  DEFAULT    3
     4: 0000000000000000     0 SECTION LOCAL  DEFAULT    4
     5: 0000000000000000     0 SECTION LOCAL  DEFAULT    5
     6: 0000000000000000     0 SECTION LOCAL  DEFAULT    7
     7: 0000000000000000     0 SECTION LOCAL  DEFAULT    8
     8: 0000000000000000     0 SECTION LOCAL  DEFAULT    6
     9: 0000000000000000    41 FUNC    GLOBAL DEFAULT    1 main
    10: 0000000000000029    20 FUNC    GLOBAL DEFAULT    1 add
    11: 0000000000000000     0 NOTYPE  GLOBAL DEFAULT  UND printf
```

▲图21-31　symtab各项内容

Symbol Table的数据结构如下：

Figure 1-15. Symbol Table Entry

```
typedef struct {
        Elf32_Word    st_name;
        Elf32_Addr    st_value;
        Elf32_Word    st_size;
        unsigned char st_info;
        unsigned char st_other;
        Elf32_Half    st_shndx;
} Elf32_Sym;
```

很显然，st_name表示的是这个Symbol的名称。但细心的读者应该能发现，它其实只是一个Word值，如何能表达出“add”这个字符串呢？答案就是st_name实际上是“add”字符串在.strtab中所对应的Index。这样的设计一方面有效解决了字符串这种可变长度的数据与其他固定长度数据如何“共存”的问题；另一方面也可以实现字符串的复用，节约了存储空间。

另外，“add”的Type是FUNC，代表它是一个函数；Ndx是Index的缩写，表示这个函数的定义是在序号为1的Section中，即“.text”段；“Value”列则表示add函数在“.text”中的偏移量，从中可以看到这个值是0x29。

那么情况真的是如此吗？我们可以通过反编译main.o来找到答案，如图21-32所示。

```
Disassembly of section .text:

0000000000000000 <main>:
   0:   55                      push   %rbp
   1:   48 89 e5                mov    %rsp,%rbp
   4:   be 02 00 00 00          mov    $0x2,%esi
   9:   bf 01 00 00 00          mov    $0x1,%edi
   e:   b8 00 00 00 00          mov    $0x0,%eax
  13:   e8 00 00 00 00          callq  18 <main+0x18>
  18:   bf 00 00 00 00          mov    $0x0,%edi
  1d:   b8 00 00 00 00          mov    $0x0,%eax
  22:   e8 00 00 00 00          callq  27 <main+0x27>
  27:   5d                      pop    %rbp
  28:   c3                      retq

0000000000000029 <add>:
  29:   55                      push   %rbp
  2a:   48 89 e5                mov    %rsp,%rbp
  2d:   89 7d fc                mov    %edi,-0x4(%rbp)
  30:   89 75 f8                mov    %esi,-0x8(%rbp)
  33:   8b 45 f8                mov    -0x8(%rbp),%eax
  36:   8b 55 fc                mov    -0x4(%rbp),%edx
  39:   01 d0                   add    %edx,%eax
  3b:   5d                      pop    %rbp
  3c:   c3                      retq
```

▲图21-32 main.o的编译结果

由图21-32我们可以清楚地看到，add在main.o文件中的偏移量确实是0x29。不过因为当前main.o还没有经过链接操作，所以各个地址值看上去还不是很正规。接下来我们就执行链接操作使其成为真正的可执行程序，所使用的命令如下所示：

```
gcc -o main main.o
```

此时我们再来反编译main文件，情况已经发生了很大的变化。如图21-33所示。

```
000000000040052d <main>:
  40052d:       55                      push   %rbp
  40052e:       48 89 e5                mov    %rsp,%rbp
  400531:       be 02 00 00 00          mov    $0x2,%esi
  400536:       bf 01 00 00 00          mov    $0x1,%edi
  40053b:       b8 00 00 00 00          mov    $0x0,%eax
  400540:       e8 11 00 00 00          callq  400556 <add>
  400545:       bf f4 05 40 00          mov    $0x4005f4,%edi
  40054a:       b8 00 00 00 00          mov    $0x0,%eax
  40054f:       e8 bc fe ff ff          callq  400410 <printf@plt>
  400554:       5d                      pop    %rbp
  400555:       c3                      retq

0000000000400556 <add>:
  400556:       55                      push   %rbp
  400557:       48 89 e5                mov    %rsp,%rbp
  40055a:       89 7d fc                mov    %edi,-0x4(%rbp)
  40055d:       89 75 f8                mov    %esi,-0x8(%rbp)
  400560:       8b 45 f8                mov    -0x8(%rbp),%eax
  400563:       8b 55 fc                mov    -0x4(%rbp),%edx
  400566:       01 d0                   add    %edx,%eax
  400568:       5d                      pop    %rbp
  400569:       c3                      retq
  40056a:       66 0f 1f 44 00 00       nopw   0x0(%rax,%rax,1)
```

▲图21-33　执行链接操作后再次反编译的结果

为了方便大家对main函数在链接前后的变化做对比观察，我们特别制作了下列表格，如图21-34所示。

链接前	链接后

0: 55
push %rbp
1: 48 89
e5 mov
%rsp,%rbp
4: be 02 00 00 00
mov $0x2,%esi
9: bf 01 00 00 00
	40052d: 55
	push %rbp
	40052e: 48 89 e5
	mov %rsp,%rbp
	400531: be 02 00 00 00
	mov $0x2,%esi
	400536: bf 01 00 00 00

mov $0x1,%edi	mov $0x1,%edi
e: b8 00 00 00 00	40053b: b8 00 00 00 00
mov $0x0,%eax	mov $0x0,%eax
13: e8 00 00 00 00	400540: e8 11 00 00 00
callq 18 <main+0x18>	callq 400556 <add>
18: bf 00 00 00 00	400545: bf f4 05 40 00
mov $0x0,%edi	mov $0x4005f4,%edi
1d: b8 00 00 00 00	40054a: b8 00 00 00 00
mov $0x0,%eax	mov $0x0,%eax
22: e8 00 00 00 00	40054f: e8 bc fe ff ff
callq 27 <main+0x27>	callq 400410 <printf@plt>
27: 5d	400554: 5d
pop %rbp	pop %rbp
28: c3	400555: c3
retq	retq

▲图21-34　对比结果

其中有差异的地方我们以阴影的方式标识出来，包括但不限于：

- 地址由相对地址变成了绝对地址

可以明显地看到各条指令的地址已经由0x00、0x01等相对地址转变成了0x40052d、0x40052e等绝对地址（虚拟内存地址）。

- 函数的跳转指令发生了变化

对于“add”这类在可执行程序内部定义的函数，我们可以直接利用它的绝对地址来实现跳转；而对于printf这种由动态链接库提供的函数则没有那么简单。因为动态链接库被加载到内存中的具体地址必须要等到运行阶段才能得到确认，所以我们需要一种更为灵活的机制来确保程序可以正常调用动态链接库中的函数。这就涉及了动态链接库的加载与运行原理了，我们将在下一小节做专门讲解。

ELF中其他常见的区段及释义如表21-6所示。

表21-6　ELF常见Section释义

Section	Description
.text	代码区段
.data	经过初始化的变量区
.bss	未初始化的变量区
.rel.text	函数的重定位信息区
.rel.data	静态变量的重定向信息区
.rel.plt	用于动态链接时提供重定向信息（如果使用了PLT） 注意：在64位机器上的名称是.rela.plt
.rel.dyn	用于动态链接时提供重定向信息（如果没有使用PLT）
.got	Global Offset Table，为重定向对象提供偏移量信息
.debug	提供调试相关信息
. strtab	String Table，用于存储各个Symbol名对应的字符串
. symtab	Symbol Table，用于存储各个Symbol的数据

.init	Executable或Shared Object中包含的用于初始化的函数
.init_array	和.init类似，提供了一组用于初始化的函数（按顺序执行）
.fini	Executable或Shared Object中包含的用于析构的函数
.fini_array	和.fini类似，提供了一组用于析构的函数（按顺序执行）

ELF文件也允许程序根据需要来提供构造和析构函数（这点和Class类很相似），分别对应.init/.init_array和.fini/.fini_array区段。当动态对象在进程中第一次被加载时，“构造”函数会首先得到调用；而当它们被卸载时，“析构”函数也同样会被执行。如果.init/.init_array在ELF中同时存在，那么前者的优先级要高于后者。利用C/C++语言编程时，开发人员可以通过给函数指定__attribute__((constructor))/((destructor))属性来生成.init/.fini区段。

值得一提的是，ELF可执行程序在运行时的内存布局大致如图21-35所示。

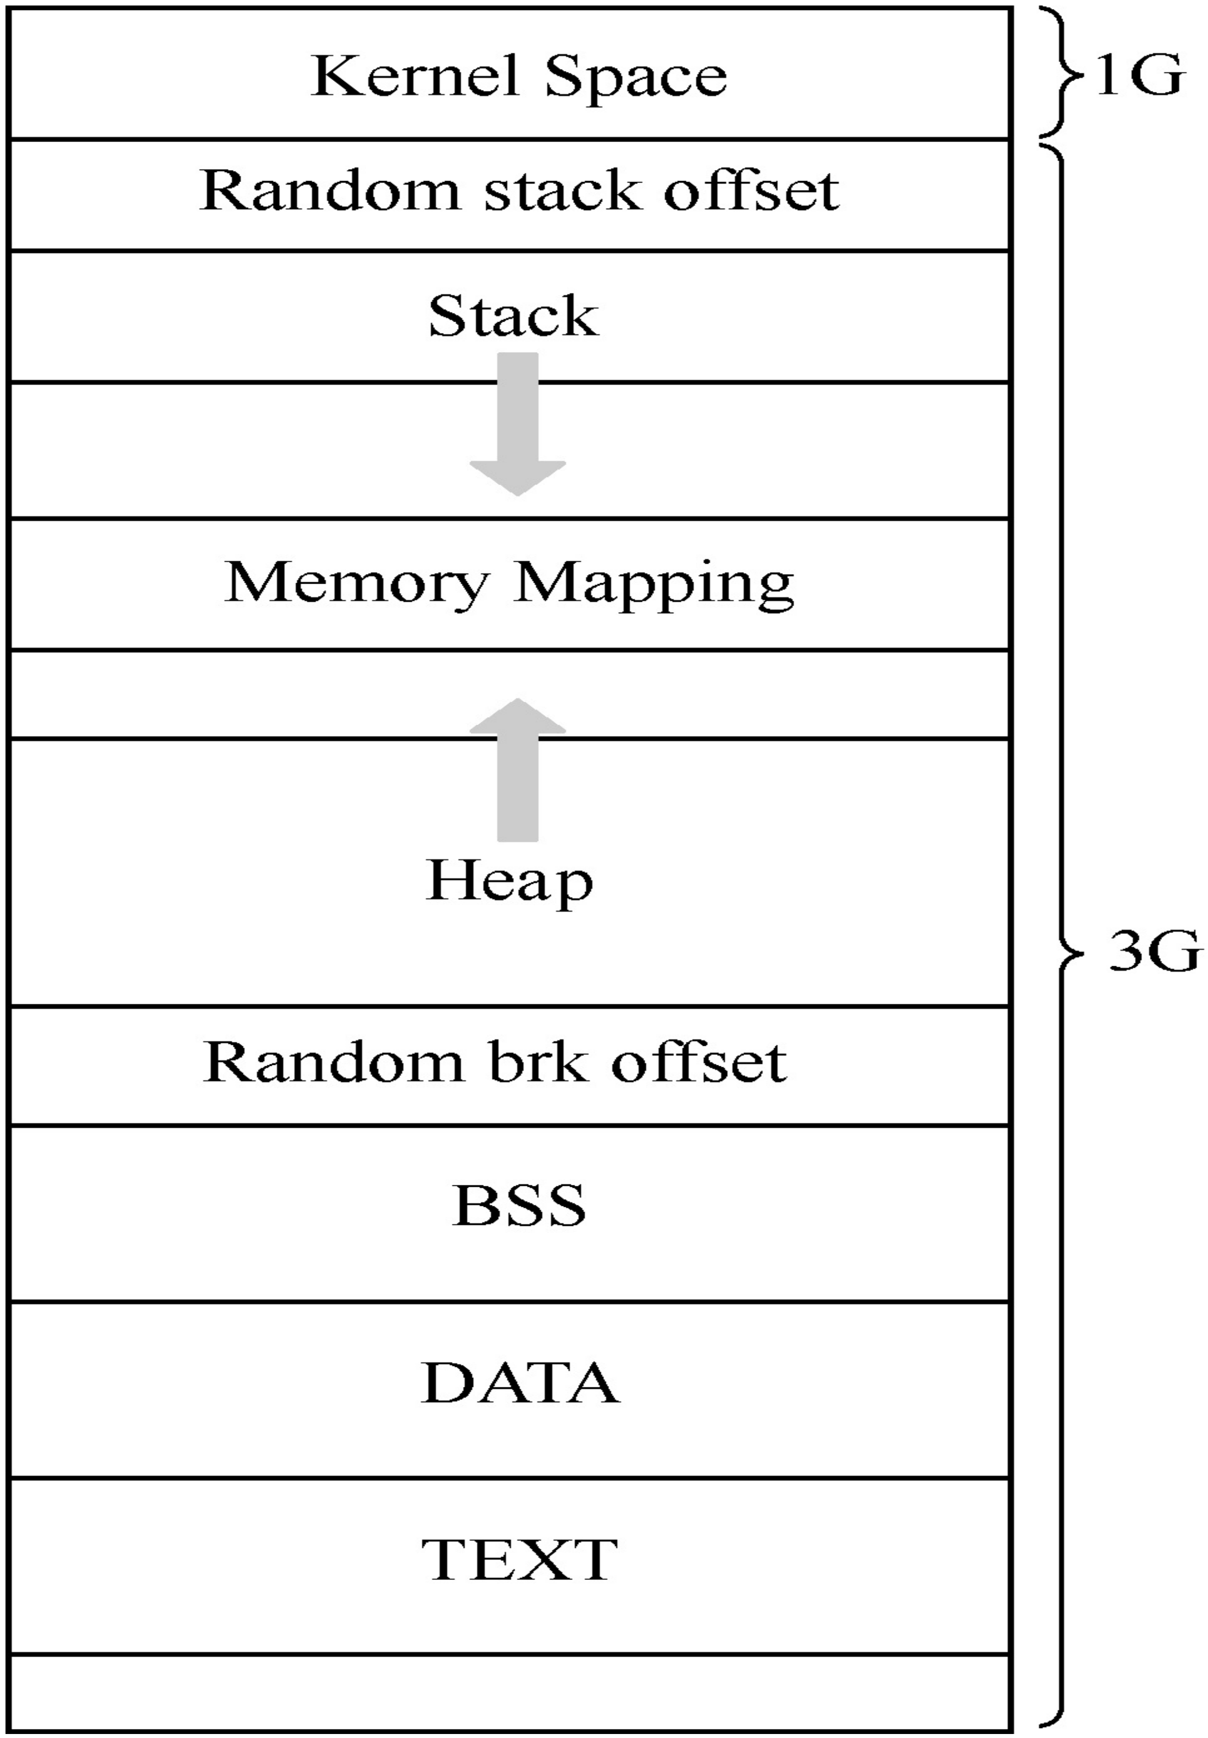

Kernel Space
1G
Random stack offset
Stack
Memory Mapping
Heap
3G
Random brk offset
BSS
DATA
TEXT

▲图21-35 ELF可执行程序典型内存布局图

因为Android虚拟机本身也是寄居在Linux应用程序之上的，所以同样遵循上述图例，这一点请大家在学习虚拟机过程中务必保持正确的认识。

21.3.2 Linux平台下ELF文件的加载和动态链接过程

静态库和动态链接库有什么区别呢？

Wiki上对静态库的释义如下所示：

“In computer science, a static library or statically-linked library is a set of routines, external functions and variables which are resolved in a caller at compile-time and copied into a target application by a compiler, linker, or binder, producing an object file and a stand-alone executable”

静态链接库的特点是会在程序的编译链接阶段就完成函数和变量的地址解析工作，并使之成为可执行程序中不可分割的一部分。这种处理手段在某种程度上也可以有效地实现代码的重复利用，使得编写程序不需要每次都从零开始，因而在程序开发的早期得到了广泛的应用——甚至是当时技术条件下的唯一选择。但是它的缺点也是比较明显的，即可执行程序的体积会随着静态链接库的增加而不断变大。另外，如果操作系统中有多个可执行程序都用到了同一个静态库A，按照静态链接的做法就需要把A分别打包进所有程序中——这显然是一种资源浪费。

与静态链接库相对应的，便是动态链接库的处理方式，我们再来看下它的定义：

“In computing, a dynamic linker is the part of an operating system that loads and links the shared libraries needed by an executable when it is executed (at "run time"), by copying the content of libraries from persistent storage to RAM, and filling jump tables and relocating pointers.”

动态链接库有如下几个核心特点：

- 动态链接库不需要在编译时就被打包到可执行程序中，而是等到后者在运行阶段再实现动态的加载和重定位。
- 动态链接库在被加载到内存中之后，操作系统需要为它执行动态链接操作。值得一提的是，有一些参考资料会把这里的链接称为“动态链接”，而将前述编译阶段的链接叫做“静态链接”；而且静态链接中也会有Relocation（Link Time Relocation），只是和动态链接中的重定位（Load Time Relocation）所针对的对象和处理过程存在差异。换句话说，只要涉及多个文件之间的链接，通常都需要重定位。只不过静态链接发生在编译阶段，而动态链接则发生在运行阶段。这些概念都很容易搞混淆，提醒大家注意区分。

实际的动态链接过程是比较复杂的，例如需要链接器的介入（链接器通常也是一个ELF文件，因而存在“蛋生鸡，鸡生蛋”的问题，解决类似问题的办法通常被称为“BootStrap”。这其中还有很多有趣的细节，有兴趣的读者可以自行查阅相关资料），需要重定位，需要有效的机制来管理所有的动态符号等。

接下来我们仍以之前的求和程序为例，进一步讲解动态链接库的工作原理：

```
/*main.c*/
#include "stdio.h"

void main()
{
     add(1,2);
     printf("This is an example");
}

int add(int value1, int value2)
{
     return value1+value2;
}
```

在这个程序中，add函数是定义在main.c中的，因而它的地址是已知的；而printf函数则由C库提供，属于“外部函数”，所以它在编译时并不会被打包到“求和”小程序中。等到“求和”程序在机器上真正

运行起来后，操作系统会把它需要的动态链接库从磁盘（或其他存储介质）加载到内存中，然后解析出（如果是启用了延时解析的话，情况会有所不同）所有它引用的外部函数的真实地址，并保证可执行程序可以正确指向这些外部函数。

那么动态链接的这些操作是在什么时候执行的呢？由前一小节的分析大家应该知道，ELF头文件中有一项代表的是程序的入口地址，即e_entry。它在求和程序中对应的具体值是：

```
Version:                             0x1
Entry point address:                 0x400440
Start of program headers:            64 (bytes into file)
```

ELF可执行程序在运行过程中的入口地址一定是e_entry吗？这个问题可以从Linux Kernel如何启动ELF程序中找到答案。当我们需要运行一个ELF程序时，内核在经过一系列操作后会调用do_execve——这个函数最终又会利用load_elf_binary来完成ELF文件的加载和解析（Linux支持多种可执行文件格式，由一个linux_binfmt结构体表示，其中包含的load_binary成员变量指向可执行文件具体的加载函数）。

函数load_elf_binary很长，我们来分段阅读：

```
static int load_elf_binary(struct linux_binprm *bprm, struct pt_r
{
     …

     /* 开始处理头文件信息 */
     if (loc->elf_ex.e_phentsize != sizeof(struct elf_phdr))
          goto out;
     if (loc->elf_ex.e_phnum < 1 ||
          loc->elf_ex.e_phnum > 65536U / sizeof(struct elf_phdr))
          goto out;
     size = loc->elf_ex.e_phnum * sizeof(struct elf_phdr);
     retval = -ENOMEM;
     elf_phdata = kmalloc(size, GFP_KERNEL);
     if (!elf_phdata)
          goto out;
```

变量loc保存的是ELF文件的头文件信息。上述代码段中，e_phnum代表的是Program Header Table的数量；e_phentsize则代表一个Program Header所占的空间大小。因为PHT区段对于可执行程序来说是

必不可少的，所以在数量上一定是>1（并且<65536）的：

```
…
for (i = 0; i < loc->elf_ex.e_phnum; i++) {
     if (elf_ppnt->p_type == PT_INTERP) {…
          retval = -ENOMEM;
          elf_interpreter = kmalloc(elf_ppnt->p_filesz,
                           GFP_KERNEL);
          if (!elf_interpreter)
               goto out_free_ph;

          retval = kernel_read(bprm->file, elf_ppnt->p_offse
                         elf_interpreter,
                         elf_ppnt->p_filesz);
          …
          interpreter = open_exec(elf_interpreter);
          …
          loc->interp_elf_ex = *((struct elfhdr *)bprm->buf)
          break;
     }
     elf_ppnt++;
}
```

上述这个for循环是整个函数的关键点之一，它的目标是通过遍历所有Program Header来查找到Interpreter，即通常所说的“解释器”段。一旦找到，我们就可以把其中的内容通过kernel_read读取到elf_ppnt->p_offset所指示的地址空间中了。

ELF文件格式有一个名为“.interp”的Section，用于指示上述的链接器的位置。例如下面是针对“求和”小程序执行“readelf -S”命令所得到的信息，大家注意看第2个区段：

```
Section Headers:
  [Nr] Name              Type             Address           Offset
       Size              EntSize          Flags  Link  Info  Align
  [ 0]                   NULL             0000000000000000  00000000
       0000000000000000  0000000000000000           0     0     0
  [ 1] .interp           PROGBITS         0000000000400238  00000238
       000000000000001c  0000000000000000   A       0     0     1
```

由“.interp”区段的Offset可知它的偏移量为00000238，我们来看一下这个地址下保存的数据：

```
0000230: 0100 0000 0000 0000 2f6c 6962 3634 2f6c  ......../lib64/l
0000240: 642d 6c69 6e75 782d 7838 362d 3634 2e73  d-linux-x86-64.s
0000250: 6f2e 3200 0400 0000 1000 0000 0100 0000  o.2.............
```

可见求和程序所使用的链接器的名称为“/lib64/ld-linux-x86-64.so.2”（这个链接器虽然表面上看是一个so文件，但事实上也是一个可执行程序），它在文件系统中的位置如图21-36所示。

▲图21-36　在文件系统中的位置

需要特别说明的是，我们的求和程序是在Linux平台下所做的实验。Android系统中的Linker与之大同小异，如下所示：

```
00000170  20 00 00 00 2f 73 79 73  74 65 6d 2f 62 69 6e 2f  | .../system/bin/|
00000180  6c 69 6e 6b 65 72 00 00  08 00 00 00 04 00 00 00  |linker..........|
```

在Android系统中，可执行程序通常会被存储在/system/bin/目录下，其中就包括了我们关心的Linker。

我们再回到load_elf_binary函数，看一下系统会利用interpreter做些什么工作：

```
if (elf_interpreter) {
     retval = -ELIBBAD;
     /* Not an ELF interpreter */
     if (memcmp(loc->interp_elf_ex.e_ident, ELFMAG, SELFMAG)
          goto out_free_dentry;
     /* Verify the interpreter has a valid arch */
     if (!elf_check_arch(&loc->interp_elf_ex))
          goto out_free_dentry;
}
```

首先需要验证interpreter的合法性，包括Magic Number是否正确；机器平台架构是否有效等：

```
if (elf_interpreter) {
     unsigned long uninitialized_var(interp_map_addr);

     elf_entry = load_elf_interp(&loc->interp_elf_ex,
                          interpreter,
                          &interp_map_addr,
                          load_bias);
     …
} else {
     elf_entry = loc->elf_ex.e_entry;
     if (BAD_ADDR(elf_entry)) {
          force_sig(SIGSEGV, current);
          retval = -EINVAL;
          goto out_free_dentry;
     }
}
```

上述这段代码是决定ELF入口地址的关键。它的处理逻辑概括起来就是：如果interpreter区段存在，那么这个ELF文件的入口地址就是load_elf_interp函数的返回值；否则就仍然采用ELF头文件信息中指定的e_entry。换句话说，ELF程序真正的入口地址取决于它在执行过程中是否需要解释器——如果答案是肯定的，那么入口就在解释器中；否则使用默认的e_entry。

理解了ELF的入口地址如何确定后，接下来我们再用nm命令分析函数符号（特别是printf这类外部函数）信息：

```
0000000000400570 T __libc_csu_init
                 U __libc_start_main@@GLIBC_2.2.5
000000000040052d T main
                 U printf@@GLIBC_2.2.5
00000000004004a0 t register_tm_clones
```

不难发现，对于main这种内部函数而言，它的地址是预先就确定的；而printf则不一样，它只是被标志为“printf@@GLIBC_2.2.5”，并没有分配具体的地址值。大家可能会有疑问，可执行程序在运行时怎么知道要加载哪些动态库呢？这些信息事实上是由.dynamic区段（.dynamic有点类似于“大总管”，它包含了所有与动态链接相关的信息）提供的。譬如从图21-37（readelf –d命令）中可以看出这个可执

行程序依赖于libc动态库（NEEDED类型），系统根据“这条线索”很容易就能判断出ELF在运行时所需要加载的动态链接库了。

有了上述知识点的铺垫后，我们现在可以给出动态链接库相关的处理过程了（以求和程序为例）。

- 在编译阶段，求和程序经历了预编译、编译、汇编及链接操作后，最终形成一个ELF可执行程序。同时求和程序所依赖的动态库会被记录到.dynamic区段中；加载动态库所需的Linker由.interp来指示。
- 当求和程序运行起来以后，系统首先会通过.interp区段找到链接器的绝对路径，然后将控制权交给它（因为求和小程序使用到了动态链接库，所以入口地址在Linker中）。
- Linker负责解析.dynamic中的记录，得出求和程序依赖的所有动态链接库，以及它们又依赖于哪些其他的动态库，以此类推。因为.dynamic中并不会指定动态库的绝对路径，所以这还涉及搜索目录的设置问题，具体细节大家可以自行查阅相关资料了解详情。
- 动态链接库加载完成后，它们所包含的export函数在内存中的地址就可以确定下来了。Linker通过预设机制（如GOT/PLT）来保证求和程序中引用到外部函数的地方可以正常工作，即完成Dynamic Relocation。

```
Dynamic section at offset 0xe28 contains 24 entries:
  Tag        Type                         Name/Value
 0x0000000000000001 (NEEDED)             Shared library: [libc.so.6]
 0x000000000000000c (INIT)               0x4003e0
 0x000000000000000d (FINI)               0x4005e4
 0x0000000000000019 (INIT_ARRAY)         0x600e10
 0x000000000000001b (INIT_ARRAYSZ)       8 (bytes)
 0x000000000000001a (FINI_ARRAY)         0x600e18
 0x000000000000001c (FINI_ARRAYSZ)       8 (bytes)
 0x000000006ffffef5 (GNU_HASH)           0x400298
 0x0000000000000005 (STRTAB)             0x400318
 0x0000000000000006 (SYMTAB)             0x4002b8
 0x000000000000000a (STRSZ)              63 (bytes)
 0x000000000000000b (SYMENT)             24 (bytes)
 0x0000000000000015 (DEBUG)              0x0
 0x0000000000000003 (PLTGOT)             0x601000
 0x0000000000000002 (PLTRELSZ)           72 (bytes)
 0x0000000000000014 (PLTREL)             RELA
 0x0000000000000017 (JMPREL)             0x400398
 0x0000000000000007 (RELA)               0x400380
 0x0000000000000008 (RELASZ)             24 (bytes)
 0x0000000000000009 (RELAENT)            24 (bytes)
 0x000000006ffffffe (VERNEED)            0x400360
 0x000000006fffffff (VERNEEDNUM)         1
```

▲图21-37 Dynamic section

Dynamic Relocation在设计时有很多需要考量的因素，例如：

- （1）链接器如何知道可执行程序中有哪些需要重定位的对象?
- （2）在没有重定位以前，这些被引用对象的地址如何表示?
- （3）如何保证在不修改代码段的情况下完成Relocation（GOT表的作用）？
- （4）如何等到动态对象被第一次访问时才去做解析操作，从而提高程序的启动速度？（PLT表的作用）

对于第1个问题，ELF专门指定了一些特殊的Section来做解答，如下所示：

```
Relocation section '.rela.dyn' at offset 0x380 contains 1 entries:
  Offset          Info           Type           Sym. Value    Sym. Name + Addend
000000600ff8  000300000006 R_X86_64_GLOB_DAT 0000000000000000 __gmon_start__ + 0

Relocation section '.rela.plt' at offset 0x398 contains 3 entries:
  Offset          Info           Type           Sym. Value    Sym. Name + Addend
000000601018  000100000007 R_X86_64_JUMP_SLO 0000000000000000 printf + 0
000000601020  000200000007 R_X86_64_JUMP_SLO 0000000000000000 __libc_start_main + 0
000000601028  000300000007 R_X86_64_JUMP_SLO 0000000000000000 __gmon_start__ + 0
```

ELF动态链接库中以“.rela”开头的Section描述的是可重定位相关的信息。比如上面的“.rela.dyn”和“.rela.plt”分别表示需要被重定位的数据对象（此时被修正的位置在“.got”和数据段中）和函数对象（此时被修正的位置在“.got.plt”中）。这一点和静态链接时的做法类似，它会有名为“.rel.text”和“.rel.data”的段来分别保存代码和数据段的重定位信息。另外，上图中除printf之外还有一些由编译器自己产生的特殊符号，不过这些并不会影响我们的分析，可以直接略过。

这样子链接器就可以清楚地知道自己的服务对象是谁了。确定了这一点以后，链接器接下来要回答的是，它采用什么方式来为这些对象服务才是最合理的呢？大家可能会在第一时间想到：可以在编译阶段只给外部对象分配一个临时地址，然后再在动态重定位时将这些临时地址替换成真实地址。这种方案理论上是可行的，但对于动态链接的场景来说并非最佳方案。试想一下，动态链接库的一个核心优势就是代码共享——不单是指进程内的代码共享，还包括进程间的代码共享——实现这个目标的前提条件之一是动态库中的代码段不需要为任何进程做定制工作。而采用上述的方案显然需要为每一个进程都做一次代码修正（因为在动态链接中被替换的临时地址是在代码段中），所以是不可取的。

ELF针对上述问题给出的方案是GOT（Global Offset Table）。它的核心思想说得直白点，就是将“变”与“不变”的部分隔离开来——通过增加一个“中间层”GOT，来保持代码段的“不变”，而把“变”的部分放到GOT表中。

但是有了GOT就“万事大吉”了吗？大家是否想过这样的问题——如果程序中有非常多需要动态链接的对象，而它们中的绝大部分在程序执行过程中是不会被使用到的，那么我们在一开始就为所有对象做解析和重定位是否合理呢？实践证明这种“一杆子”的做法确实会影响程序

的运行效率，特别是它的启动速度。聪明的人们立即又想到了有没有一种Lazy Binding的方法来在“需要动态对象的时候”才对它做重定位呢？这就是PLT的存在价值了。

接下来我们仍然以求和程序为例子，来详细分析下GOT和PLT两大机制的实现原理。

先来看下main函数对应的汇编代码：

```
000000000040052d <main>:
  40052d:       55                      push   %rbp
  40052e:       48 89 e5                mov    %rsp,%rbp
  400531:       be 02 00 00 00          mov    $0x2,%esi
  400536:       bf 01 00 00 00          mov    $0x1,%edi
  40053b:       b8 00 00 00 00          mov    $0x0,%eax
  400540:       e8 11 00 00 00          callq  400556 <add>
  400545:       bf f4 05 40 00          mov    $0x4005f4,%edi
  40054a:       b8 00 00 00 00          mov    $0x0,%eax
  40054f:       e8 bc fe ff ff          callq  400410 <printf@plt>
  400554:       5d                      pop    %rbp
  400555:       c3                      retq
```

大家注意看一下40054f这一行汇编语句：

```
callq  400410 <printf@plt>
```

这里通过callq指令调用了一个地址为0x400410的目标位置，从释义来看它属于.plt区域。所以我们反编译.plt段来做跟进分析：

```
0000000000400410 <printf@plt>:
  400410:       ff 25 02 0c 20 00       jmpq   *0x200c02(%rip)        # 601018 <_GLOBAL_OFFSET_TABLE_+0x18>
  400416:       68 00 00 00 00          pushq  $0x0
  40041b:       e9 e0 ff ff ff          jmpq   400400 <_init+0x20>
```

<printf@plt>的实现并不复杂：0x400410处是一条跳转指令，而且跳转地址被保存于0x200c02指针所指向的地址。通过0x400410语句后面的注释不难发现，0x200c02对应的是Global Offset Table偏移0x18的地方。

此时分为如下两种情况（以“求和”程序为例）：

- 当printf被第1次访问时

当我们第一次调用printf这个函数时，程序首先通过callq调用<printf@plt>，然后在执行0x400410语句时跳转到GOT表中。可是此时printf函数的真实地址还未得到解析，换句话说GOT+0x18的地方保存的是0x400416——所以绕了一圈又回到了plt中。而0x400416是条堆栈语句，目的是为了保存printf在rel.plt中的序号（rel.plt中的信息包括了printf在GOT中的地址，以及它的名称“printf”，以便后续查找目标符号真实地址，并将结果值保存到正确的GOT地址中）。紧接着执行的0x40041b也是一条跳转语句，跳转目标是Plt[0]。PLT表的第一项是比较特殊的，它的工作简单来说就是为跳转到GOT[2]做准备。而GOT[0]、GOT[1]和GOT[2]都是系统预先保留的，其中GOT[2]中保存的是一个名为_dl_runtime_resolve的函数，用于解析某函数名（如“printf”）的真实地址。至此目标函数在第一次被访问时就可以得到正确的解析了。

- 当printf非首次执行时

有了上一步的努力后，GOT表中已经保存好printf的真实地址了。换句话说，当程序再次执行到0x400410这个位置时就不会再绕回0x400416，而是可以直接跳转到目标对象的真实地址了。

我们以图21-38来帮助大家更好地理解上述讲解的整个过程（实际情况会更复杂一些，但原理是一样的）：

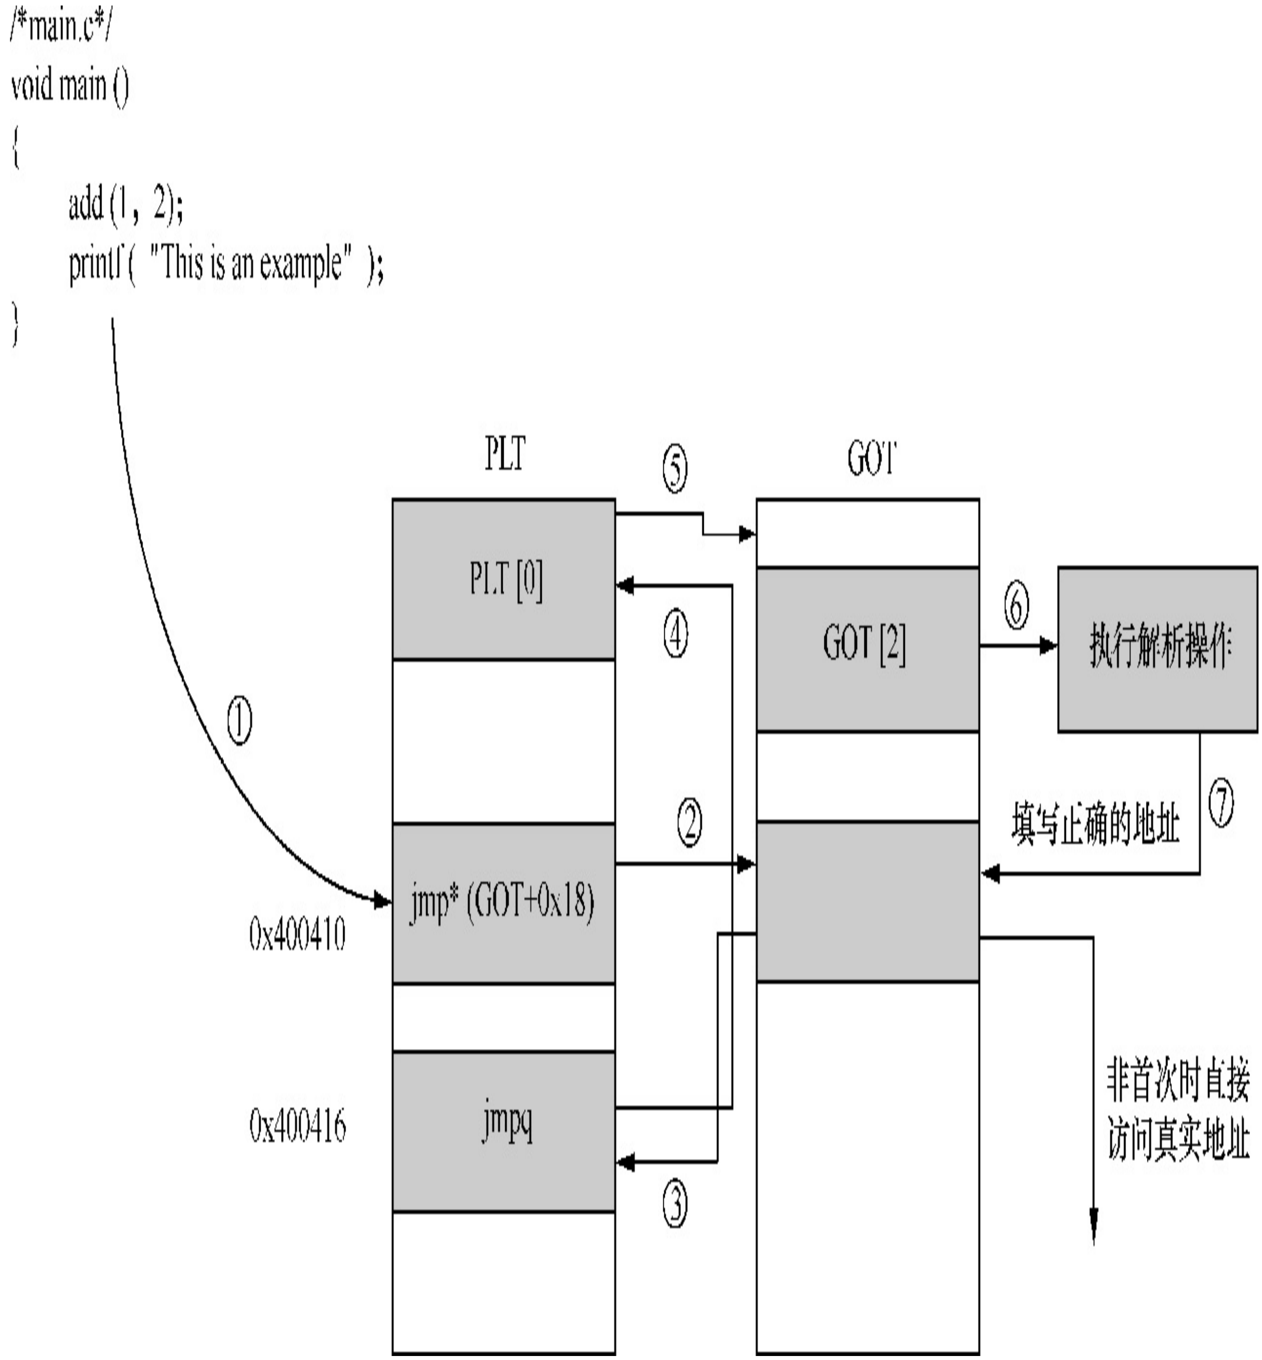

▲图21-38　GOT和PLT机制示意图

值得一提的是，不少开发人员经常分不清编译器提供的-fpic选项的作用。这个选项从字面意思上理解是“Position Independent Code”，即位置无关代码。确切地讲，是指代码段（.text）在运行时不需要重新定位（Relocation）。从本小节的分析中我们知道这一点是实现模块真正共享的关键，因为代码段的重新定位意味着使用者们需要

各自拥有一份模块的复制，这显然是一种无谓的资源浪费。另外，地址无关技术不光适用于动态链接库，对可执行文件也是同样有效的（此时对应的选项是-fpie）。

我们在这两个小节中讲解的内容都是围绕C语言展开的，那么C++中的情况会不会有所差异呢？总体来讲，它们二者在最终形式上是大同小异的，主要的区别会体现在如下几个方面：

（1）Name Mangling

Mangle的字面意思是“损坏”，不难理解这是C++针对函数和变量采用的一种改名机制。这样做的原因有很多个，譬如为了支撑C++的重载功能——因为函数如果名字相同但参数不同，那么编译后的函数如果采用原先的名字就会出现重名现象。Name Mangling可以有效解决这个问题，它会综合考虑函数名和函数相关的信息（如参数）从而合成出一个全新的函数名称。C++标准中并没有对Mangling的具体做法做强制约束，这就意味着合成规则主要取决于编译器本身的设计。这一点对开发者的可能影响是我们无法通过函数名预先准确判断出它在Name Mangling后的结果，如此一来dlsym这样的函数在某些场景下可能就无计可施了——解决这个问题的一个可选的方法是在C++代码中使用extern“C”，以防止Name Mangling的发生。

（2）类的加载

我们知道，C++是一门面向对象的语言，类的使用非常普遍。但是如何从一个C++代码生成的库中创建对象实例并不是件容易的事。不过这个问题已经有不少人给出了答案，限于篇幅我们不做深入分析，有兴趣的读者可以自行搜寻相关资料了解详情。

21.3.3 Android Linker和动态链接库

21.3.3.1 Android中动态库的隐式调用与链接

通过前面小节的学习，我们知道ELF格式的可执行程序会提供一个名为.interp的区段，用于记录程序运行时所使用的动态链接器。当ELF程序从内核态切换到用户态运行时，首先被启动的就是它所指定的Linker（如果这个程序依赖于动态链接库的话）。紧接着动态链接器会主动帮助程序加载支撑其正常工作的动态链接库文件，这一过程我们称

为动态库的隐式调用。

从Android程序提供的.interp区段中，我们不难发现它所指定的Linker是/system/bin/linker，那么这是在什么时候做的配置呢？

事实上Android系统在编译过程中做了充分的封装隐藏，因而上述配置过程对开发人员而言几乎是透明的——编译系统利用统一的模板来帮助程序完成对.interp区域的填充，如下所示：

```
/*build/core/definitions.mk*/
define transform-o-to-executable-inner
$(hide) $(PRIVATE_CXX) -pie \
     -nostdlib -Bdynamic \
     -Wl,-dynamic-linker,$(PRIVATE_LINKER) \
     -Wl,--gc-sections \
     -Wl,-z,nocopyreloc \
  …
```

其中“-dynamic-linker”选项就用于指定程序所需的动态链接器，后面紧跟着的$（PRIVATE_LINKER）变量通常会被赋值为：/system/bin/linker（32位平台的情况）或者/system/bin/linker64（64位平台的情况）。

Android Linker在AOSP源码工程中所对应的路径是/bionic/linker，由它的编译脚本不难看出，Linker也是一个ELF可执行文件：

```
/*bionic/linker/Android.mk*/
LOCAL_MODULE := linker
LOCAL_MODULE_STEM_32 := linker
LOCAL_MODULE_STEM_64 := linker64
LOCAL_MULTILIB := both
…
include $(BUILD_EXECUTABLE)
```

接下来我们结合Linker来讲解Android中动态库的隐式调用和链接流程。Android系统中的进程和普通的Linux进程本质上并没有什么不同，它们在启动时都会调用系统接口execv来执行具体的程序代码。函数execv经过一系列处理后，先进入load_elf_binary加载ELF文件，继而又调用load_elf_interp。后面这个函数负责从目标程序的.interp区段中将指定的动态链接器加载到内存中，并进入load_elf_interp的返

回值（也就是Linker的入口点）中执行。这和我们前面小节分析的Linux中动态库的加载过程是一致的。

此时程序就成功地从内核态转入用户态了——换句话说，程序主体部分的加载工作是由操作系统在内核态直接完成的，而对于动态链接库的加载和处理权利则将交由“用户”，即Linker来掌控。

Linker的入口地址对应的是begin.S中的_start函数，它会进一步调用__linker_init来进行初始化，包括解决Linker自身的重定位问题。这里就出现了一个有趣的现象：因为Linker的职责之一就是帮助程序的其他模块实现对外部对象的引用问题，所以在它初始化时，能完成重定位任务的“鸡”显然还没“生”出来（解决这类问题的方法又被称为自举代码）。所以在__linker_init初始化完成之前，Linker不能访问任何外部变量、函数，否则将导致segfault的运行时错误。

因为Linker本身也是一个ELF格式的文件，所以其内部结构亦遵从ELF规范，这些信息会被收集到一个名为linker_so的soinfo结构体变量中。接着__linker_init通过prelink_image来解析linker文件中的dynamic区段信息，并做好各项Sanity Checks（例如：Linker不能依赖于其他动态库，因而DT_NEEDED的数量只能为0，否则就会触发Sanity错误）。紧接着linker就可以在link_image中进行针对自身的重定位工作了，大家可以阅读源码了解具体的实现细节。一旦Linker的自举成功完成后，它就可以放心地调用外部函数来实现其核心功能——动态链接了，具体的函数实现在__linker_init_post_relocation中。简单而言，Linker会按如下优先级去多个路径下查找程序所依赖的动态库：

- DT_RPATH

  这是包含在dynamic区段中的一个表项信息。

- LD_LIBRARY_PATH

  这是一个系统环境变量，可以通过getenv函数来获取。

- LD_PRELOAD

这也是一个系统环境变量。不过出于安全原因的考虑，如果程序设置了setuid/setgid，那么这两个环境变量都会被忽略。

- 其他缺省目录

这个查找过程同时还会按照广度优先的搜索顺序来递归解决动态库对其他库的依赖关系。另外，加载动态库文件只是其中的一个环节，另一个关键步骤就是对这些库执行链接操作，即soinfo::link_image所需要完成的任务。这同时也是Android系统和Linux内核有差异的地方：后者采用的是Lazy Binding的方式，意即只有等到PLT表中的元素第一次被执行时，才会去解析获取真实的地址；而Android系统则在开始时就直接将GOT中的元素全部解析完成。这一点我们从Linker.cpp代码中也可以得到验证，如下所示：

```
/*bionic/linker/linker.cpp*/
bool soinfo::prelink_image() {…
      case DT_PLTGOT:
#if defined(__mips__)
        // Used by mips and mips64.
        plt_got_ = reinterpret_cast<ElfW(Addr)**>(load_bias + d->
#endif
        // Ignore for other platforms... (because RTLD_LAZY is no
        break;
```

一旦Link工作成功完成，程序就可以正常使用这些隐式调用的动态链接库了。其中还有很多实现细节，建议大家可以自行结合源码来阅读理解。

21.3.3.2 Android中动态库的显式调用与链接

动态链接库的显式调用指的是程序利用操作系统提供的接口，在运行过程中主动加载动态链接库的过程。Android系统提供的动态库的显式调用方法包括但不限于：

- Java层：System.loadLibrary和System.load

如果开发人员需要在Java层发起对so动态链接库的加载动作，那么可以使用System包提供的loadLibrary或者load接口。这两个函数的原型如下：

```
static void loadLibrary (String libName);
static void load (String pathName);
```

loadLibrary和load之间的差异主要体现在函数参数上——前者只需要指出动态链接库的名称就可以了，系统会负责在预先设置的路径中去查找并加载正确的so库；相对而言load则为开发者提供了更灵活的方式，允许开发者将动态库存储到任何程序有权限访问的地方，并由pathName给出完整的加载路径。

值得一提的是，loadLibrary和load这两个函数在Native层也一定会有对应的实现——那么包含它们的so库又是在什么时候、如何被加载的呢？答案是Runtime在启动过程中通过LoadNative Library来加载名称为“libjavacore.so”的动态链接库，后者就是Java层这两个常用加载函数的 实现主体。

- Native层：dlopen等标准接口

Android是基于Linux实现的，因而它也支持类似dlopen、dlsym等标准的动态链接库操作接口。

建议大家可以从虚拟机全局的角度来理解Android中的动态链接库，或许可以取得更好的效果。示意如图21-39所示。

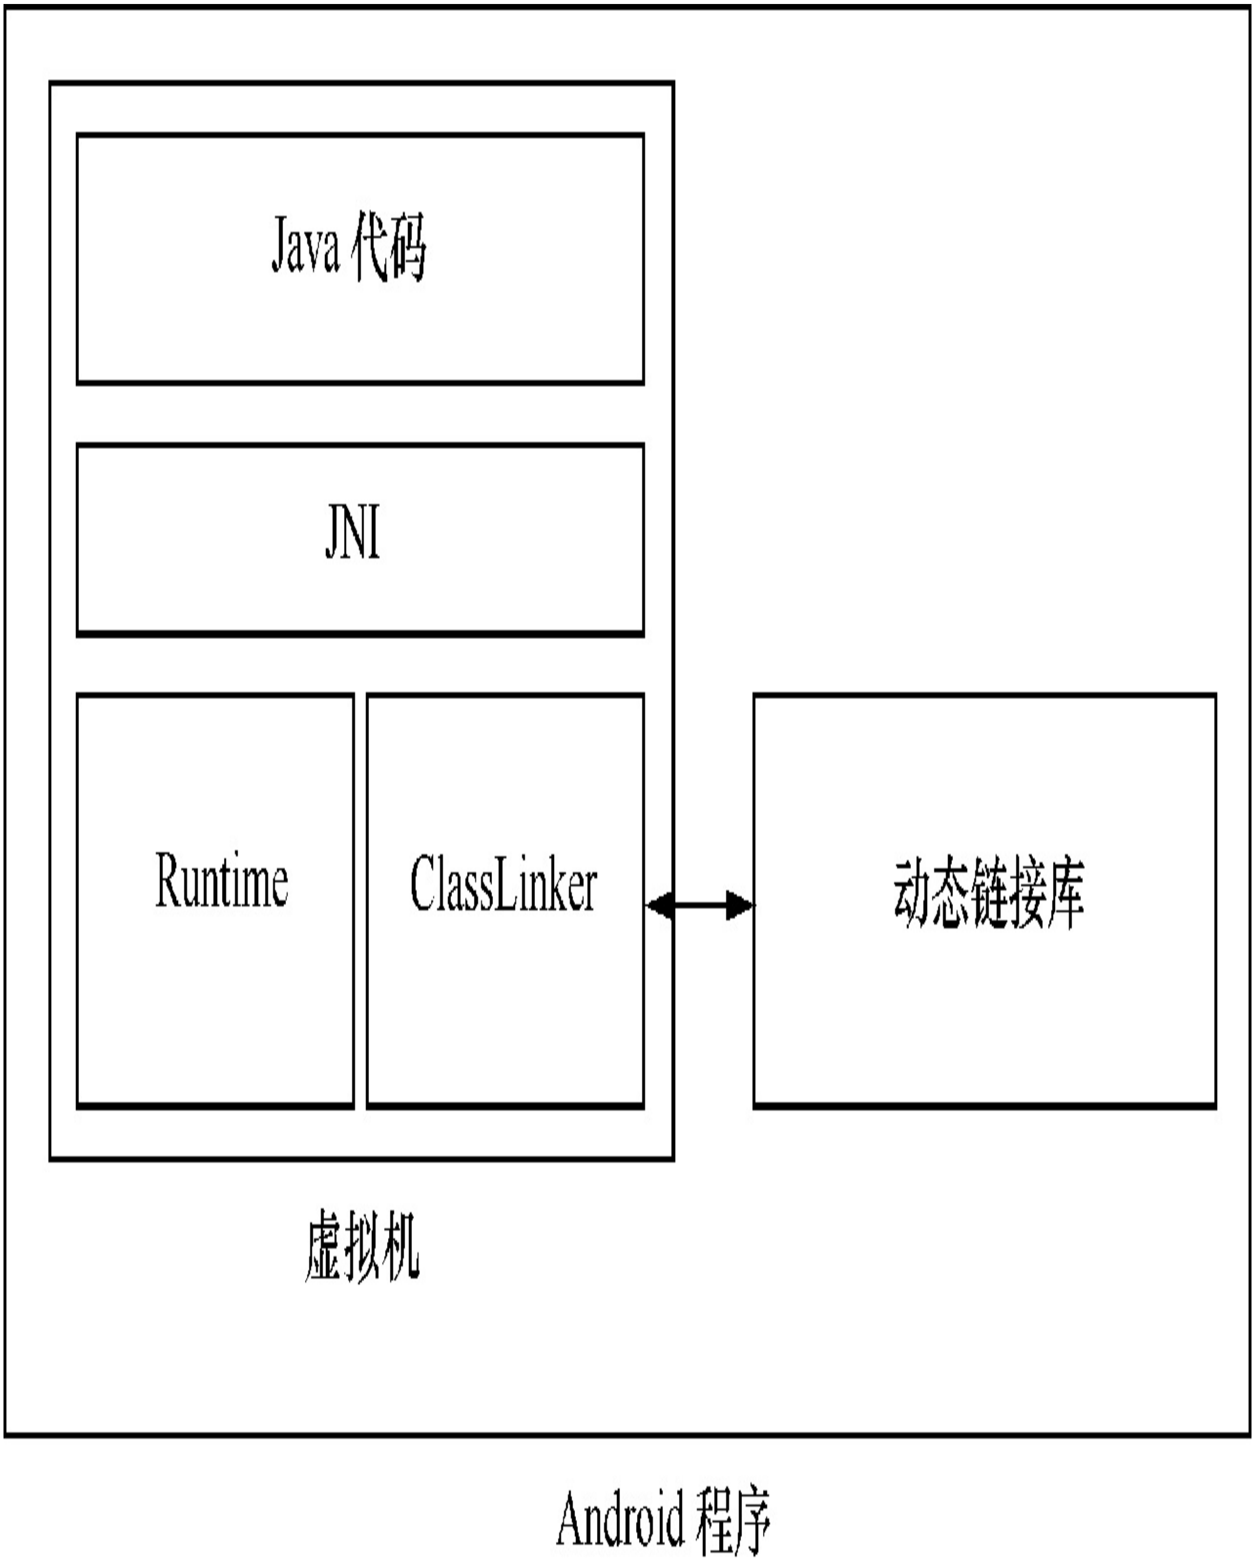

▲图21-39　从虚拟机层面理解动态链接库

本小节接下来的内容将按照以下两条线索来组织：

第一，我们将向大家介绍Android N版本中一个重要的特性更新：即如何利用命名空间（Namespace）来阻止程序访问非法的NDK接口；

第二，System.loadLibrary是应用程序最常用的动态库加载函数，所以我们将以此为突破口，通过分析它的内部实现来达到两个目的：向大家展示上述Namespace机制是如何发挥作用的；以及理解Android系统对动态链接库的显式调用链接过程。

Google为什么在Android N版本限制程序访问非法（如Non-Public）的NDK接口呢？

这是因为非法（如Non-Public）的NDK无论从接口形式或是内部实现来看都有可能随着Android版本的更新换代而发生改变，从而导致依赖它们的程序产生不可预期的致命问题。Android系统从OpenSSL切换到BoringSSL就是一个很好的范例——所有直接依赖于前者所提供的动态库文件的程序都有可能在某些Android设备上无法正常工作。

不过Android N版本暂时没有采用“一棒子打死”的暴力机制（即直接禁止这种非法事件的发生），而是为那些执行了非法引用的程序提供了各种警告信息。所以当程序中出现了如下所示的Error日志时，开发人员就应该特别注意了：

（1）Example Java error:

java.lang.UnsatisfiedLinkError: dlopen failed: library "/system/lib/libcutils.so"

is not accessible for the namespace "classloader-namespace"

（2）Example NDK error:

dlopen failed: cannot locate symbol "__system_property_get" referenced by ...

另外警告信息还会以UI弹窗的方式在Android设备中显示，以达到更好的警示效果。

那么Android系统判定程序引用了非法接口的依据是什么呢？接下

来我们将结合System. loadLibrary的内部实现来为大家揭开谜底。

Java函数System.loadLibrary首先会调用Runtime.getRuntime().loadLibrary0，后者又分别经过doLoad和nativeLoad进入到Native层，对应代码如下：

```
/*libcore/ojluni/src/main/native/Runtime.c*/
Runtime_nativeLoad(JNIEnv* env, jclass ignored, jstring javaFilen
                jobject javaLoader, jstring javaLibrarySearchPath
{
    return JVM_NativeLoad(env, javaFilename, javaLoader, javaLibr
}
```

为了保证后向兼容性，JVM_NativeLoad会根据当前程序所面向的SDK版本来决定是否要沿用之前的动态库处理方式（version<=23），即不强制采用Namespace机制。

随后JVM_NativeLoad通过JavaVM中的LoadNativeLibrary进入下一步工作，其核心源码实现如下所示：

```
/*art/runtime/java_vm_ext.cc*/
bool JavaVMExt::LoadNativeLibrary(JNIEnv* env,
                            const std::string& path,
                            jobject class_loader,
                            jstring library_path,
                            std::string* error_msg) {…
  SharedLibrary* library;
  Thread* self = Thread::Current();
  {
    // TODO: move the locking (and more of this logic) into Libra
    MutexLock mu(self, *Locks::jni_libraries_lock_);
    library = libraries_->Get(path); //首先判断是否已经加载过这个libra
  }
  …
  Locks::mutator_lock_->AssertNotHeld(self);
  const char* path_str = path.empty() ? nullptr : path.c_str();
  void* handle = android::OpenNativeLibrary(env,
                                     runtime_->GetTargetSdkVersio
                                     path_str,
                                     class_loader,
                                     library_path);//

  bool needs_native_bridge = false; //是否需要Native Bridge的辅助
  if (handle == nullptr) {//进入此分支说明前述通过正常途径打开library失
```

```
    if (android::NativeBridgeIsSupported(path_str)) {
      handle = android::NativeBridgeLoadLibrary(path_str, RTLD_NO
      needs_native_bridge = true;
    }
  }
  …
  bool created_library = false;
  {
    // Create SharedLibrary ahead of taking the libraries lock to
ordering.
    std::unique_ptr<SharedLibrary> new_library(
        new SharedLibrary(env, self, path, handle, class_loader,
                 class_loader_allocator));
    /*可能有多个线程都在尝试打开library,需要保证竞争条件下的正确性*/
    MutexLock mu(self, *Locks::jni_libraries_lock_);
    library = libraries_->Get(path);
    if (library == nullptr) {  // We won race to get libraries_lo
      library = new_library.release();
      libraries_->Put(path, library);
      created_library = true;
    }
  }
  …
  bool was_successful = false;
  void* sym;
  if (needs_native_bridge) {
    library->SetNeedsNativeBridge();
  }
  sym = library->FindSymbol("JNI_OnLoad", nullptr);
  …
  library->SetResult(was_successful);
  return was_successful;
}
```

LoadNativeLibrary的目标用一句话来概况，就是尝试利用各种可能的手段去加载动态链接库，然后找到并执行其中的JNI_OnLoad接口——这个函数是Jni库的首选入口，开发人员通常会利用它来完成一系列的初始化操作。不过系统并不要求它必须存在，所以即便是最终找不到这个函数，也并不会引发致命的错误（除了此时会有Warning信息打印出来）。

细心的读者一定已经发现了LoadNativeLibrary中充斥着大量“Native Bridge”相关的代码。简单来说这项技术用于处理当前系统平台的指令集和目标对象（Library）的指令集不一致时的兼容性问题。举个例子来说，Android模拟器为了达到提速的目的，通常会编译

成X86版本来直接运行于开发机之上；那么问题就来了，对于一个只提供了Arm版本的动态链接库文件的APK来说，如何保证它也可以在X86模拟器上正常运行呢？这就是Native Bridge所要解决的问题了，它负责在两种不同的指令集之间建立起一个“桥梁”，以此来保证双方的兼容性。后续小节对Native Bridge还有专门的介绍，我们这里先不做过多阐述。

抛开与Native Bridge相关的处理，LoadNativeBridge就容易理解了。它首先会判断目标Library是否曾经已经被加载过，依据在于libraries->Get（path）是否为空。其中libraries_是用于管理所有已加载链接库的全局变量。不过即便Library曾经被加载过，也还需要特别注意以下两种情况：

- 之前加载Library时使用的Class Loader和当前的Class Loader不一致时

根据Java规范的要求，同一个Library是不能被多个Class Loader所加载的。因而这种情况下LoadNativeBridge的返回值是false，表示本次Class Loader任务失败。

- 两个Class Loader一致的情况

说明之前这个Class Loader已经“拥有”了目标Library的“控制权”，所以LoadNativeBridge直接返回true。

交由libraries_管理的实际上是一个SharedLibrary对象，后者包含了与目标库相关的更多信息。例如Library对应的Class Loader是谁，是否需要Native Bridge，对象库的路径等。创建SharedLiabrary的过程中还有一个需要注意的地方，即如果有其他线程也在尝试加载相同的动态链接库时，就需要使用Locks::jni_libraries_lock_锁来保护资源竞争的情况下不出异常。

从LoadNativeLibrary的源码不难看出，正常途径下加载library利用的是OpenNativeLibrary这个函数。这同时也是Android N版本中新增的一个函数，用于替代旧版本中直接使用dlopen来加载动态库的方式：

```
/*system/core/libnativeloader/native_loader.cpp*/
void* OpenNativeLibrary(JNIEnv* env,
                        int32_t target_sdk_version,
                        const char* path,
```

```
                        jobject class_loader,
                        jstring library_path) {
#if defined(__ANDROID__)
  UNUSED(target_sdk_version);
  if (class_loader == nullptr) {
    return dlopen(path, RTLD_NOW);
  }

  std::lock_guard<std::mutex> guard(g_namespaces_mutex);
  android_namespace_t* ns = g_namespaces->FindNamespaceByClassLoa

  if (ns == nullptr) {
    ns = g_namespaces->Create(env, class_loader, false, library_p
    if (ns == nullptr) {
      return nullptr;
    }
  }

  android_dlextinfo extinfo;
  extinfo.flags = ANDROID_DLEXT_USE_NAMESPACE;
  extinfo.library_namespace = ns;

  return android_dlopen_ext(path, RTLD_NOW, &extinfo);
#else
  UNUSED(env, target_sdk_version, class_loader, library_path);
  return dlopen(path, RTLD_NOW);
#endif
}
```

上述代码段的处理逻辑比较简单：首先利用FindNamespaceByClassLoader来查找当前ClassLoader是否有相关联的Namespace（所有Namespace都保存在LibraryNamespaces中一个名为namespaces_的全局变量中）。如果答案是肯定的话，那么接下来就可以调用android_dlopen_ext直接进入下一步；否则我们还需要通过g_namespaces->Create来创建一个Namespace。需要注意的是，因为系统在创建ClassLoader时会同时申请Namespace（具体处理函数是CreateClass LoaderNamespace），所以只有某些特殊情况下才会出现ns==nullptr的情况。

NameSpace的数据结构定义如下所示：

```
struct android_namespace_t {…
     private:
  const char* name_; //NameSpace名称
```

```
  bool is_isolated_; //是否需要隔离。非隔离情况下可以访问所有library
  std::vector<std::string> ld_library_paths_; //程序的链接路径
  std::vector<std::string> default_library_paths_; //默认可访问的路径
  std::vector<std::string> permitted_paths_; //被允许访问的路径
  soinfo::soinfo_list_t soinfo_list_; //已经加载了的library所组成的列
```

按照Android系统的设计，NameSpace主要包括下面4类：public、default、anonymous、classloader。

它们的定义分别如下所示：

- （1）Public Namespace

Public类型的Namespace实际上并不属于android_namespace_t对象，而只是一个公共的library库列表。通常情况下，系统会从以下两个路径中加载获取公共库列表：

```
/etc/public.libraries.txt
/vendor/etc/public.libraries.txt
```

- （2）Default Namespace

```
  const char* name_:  "(default)"
  bool is_isolated_:    false
```

std::vector<std::string> ld_library_paths_:kDefaultLdPaths或者kAsanDefaultLdPaths

- kDefaultLdPaths和kAsanDefaultLdPaths是两个预设的列表，根据当前所用linker种类的不同来区分。其中kDefaultLdPaths的定义如下：

```
static const char* const kDefaultLdPaths[] = {
#if defined(__LP64__)
  "/system/lib64",
  "/vendor/lib64",
#else
  "/system/lib",
  "/vendor/lib",
#endif
  nullptr
};
```

std::vector<std::string> default_library_paths_：和上述ld_library_paths_赋值相同

std::vector<std::string> permitted_paths_：NULL

- （3）Classloader Namespace

前面提到的g_namespaces->Create虽然也用于生成这种类型的Namespace，不过正常情况下系统会在加载APK时就预先创建一个ClassLoader以及与之关联的Namespace。这个过程的流程图如图21-40所示。

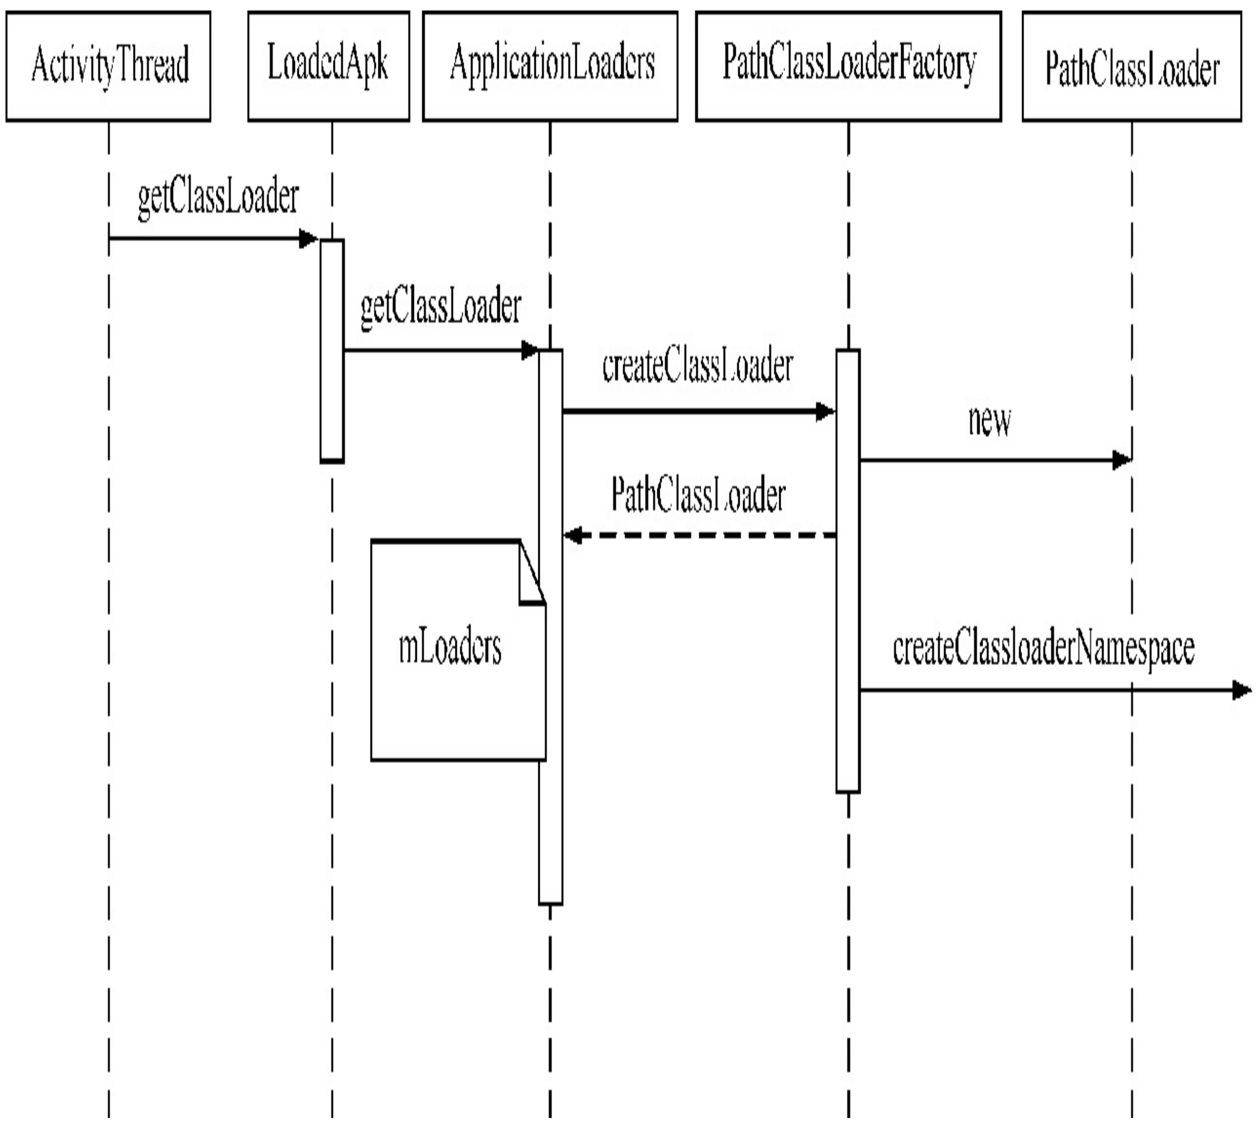

▲图21-40　APK加载过程中的namespace创建

LoadedApk用于管理应用程序的APK资源，它通过ApplicationLoaders来管理应用层创建的ClassLoaders——这些ClassLoader多数属于PathClassLoader，而且还会同步生成与之相关联的NameSpace。

我们将getClassLoader@LoadedApk.java函数中与Namespace相关的部分摘录如下：

```
public ClassLoader getClassLoader() {…
            mClassLoader = ApplicationLoaders.getDefault().getCla
                    mApplicationInfo.targetSdkVersion, isBundledA
                    librarySearchPath, libraryPermittedPath, mBas
…
```

其中librarySearchPath是指App中JNI Libraries所存放的路径（Instrumentation的情况会略有差异）；libraryPermittedPath则是系统分配给App的/data目录下用于保存数据的具体路径。另外，系统程序可访问的lib范围比第三方程序要大得多，这是利用如下语句做到的：

```
            if (mApplicationInfo.isSystemApp()) {
                isBundledApp = true;
               libPaths.add(System.getProperty("java.library.path
                libraryPermittedPath += File.pathSeparator +
                                        System.getProperty("java.
            }
```

这样一来，Class Loader Namespace中各项参数的定义如下：

const char* name_: " classloader-namespace"

bool is_isolated_: true

std::vector<std::string> ld_library_paths_: NULL

std::vector<std::string> default_library_paths_: 同上面的librarySearchPath

std::vector<std::string> permitted_paths_: 同上面的

libraryPermittedPath

我们再回到OpenNativeLibrary中继续分析。如果当前环境是Android系统，那么下一步将调用android_dlopen_ext；否则直接使用dlopen这个标准接口。这两个函数的功能是基本一致的，因而我们挑选dlopen来做一下讲解。它的函数原型如下：

```
void* dlopen(const char*  filename, int flag);
```

第一个参数filename表示要打开的动态库的名称；另一个参数flag的可选值和释义如表21-7所示。

表21-7　dlopen的flag参数释义

<table>
<tr><td rowspan="2">解析方式</td><td>RTLD_LAZY</td><td>延迟绑定，即直到引用对象被执行时再进行解析操作。换句话说，如果目标对象一直未被执行，那么它将永远不会得到解析。需要注意的是，这个选项只对函数引用有效，变量引用则总是会被立即解析</td></tr>
<tr><td>RTLD_NOW</td><td>当指定了此标志，或者设置了环境变量LD_BIND_NOW，那么动态库中的所有未定义符号在dlopen返回之前都会被解析</td></tr>
<tr><td rowspan="2">作用范围</td><td>RTLD_GLOBAL</td><td>这个动态库中定义的符号对于后续加载的其他动态库都是可用的</td></tr>
<tr><td>RTLD_LOCAL</td><td>作用范围的默认值。它的含义和上面一项正好相反，即当前动态库中定义的符号对于后续加载的其他动态库是不可用的</td></tr>
<tr><td rowspan="2">作用方式</td><td>RTLD_NODELETE</td><td>在dlclose时不卸载动态库。那么后续如果该动态库被重新加载的话，其中的静态变量就不需要重新初始化了</td></tr>
<tr><td>RTLD_NOLOAD</td><td>不加载动态库。常用于测试该动态库是否已经存在</td></tr>
</table>

另外，dlopen还支持将它的第一个函数参数设置为NULL，这种情况

下获取到的返回值代表的是主程序的句柄。利用这个返回值来进一步调用dlsym()，意味着开发者希望在主程序中搜索Symbols——搜寻顺序首先是考虑程序启动时加载的所有动态共享库，然后是那些通过dlopen打开且指定了RTLD_GLOBAL标志的动态库。

在Android系统中，android_dlopen_ext又将调用dlopen_ext，继而进入do_dlopen执行动态库的加载和链接过程（其原理与前面小节介绍的显式加载和链接过程本质上并没有太多区别，有兴趣的读者可以自行分析其中的代码实现）。

我们这里重点分析一下do_dlopen中与Namespace相关的实现：

```
/*bionic/linker/linker.cpp*/
void* do_dlopen(const char* name, int flags, const android_dlexti
                void* caller_addr) {
  soinfo* const caller = find_containing_library(caller_addr);
  …
  android_namespace_t* ns = caller != nullptr ? caller->get_names
if (extinfo != nullptr) {…
    if ((extinfo->flags & ANDROID_DLEXT_USE_NAMESPACE) != 0) {
      if (extinfo->library_namespace == nullptr) {
        DL_ERR(…);
        return nullptr;
      }
      ns = extinfo->library_namespace;
    }
}
  …
  soinfo* si = find_library(ns, name, flags, extinfo, caller);
  if (si != nullptr) {
    si->call_constructors();
    return si->to_handle();
  }

  return nullptr;
}
```

首先通过find_containing_library来找出调用者所属的模块，判断的依据是调用者所在的地址属于哪个区域。紧接着可以分为两种情况：

- caller != nullptr

这种情况下我们直接利用get_namespace来获取调用者的NameSpace对象，后者则是So文件在加载过程中分配的，而且通常被调用者的NameSpace还会继承于它的调用者。换句话说，ELF中的首个程序模块（即程序主体）是本程序所能获得的权限范围的关键。

按照Android系统的设计，首个程序模块（带有标志FLAG_EXE）将在__linker_init_post_relocation中完成它的默认权限配置，并将结果保存在名为g_default_namespace的全局变量中。

- caller == nullptr

如果调用方没有相关联的Namespace，那么直接使用Anonymous Name Space，这或许也是它的名称中“匿名”所要表达的含义。

不过上述得到的Namespace可能还不是最终的结果，这取决于extinfo中的标志ANDROID_DLEXT_USE_NAMESPACE是否有效。比如在我们这个场景下，OpenNativeLibrary就设置了自己的ClassLoader Namespace，因而此时将优先使用后面这个值。

经过上述这些步骤，现在我们已经可以确定出此次加载动态库的所对应的正确的Name Space了。接下来要做的就是把这个结果应用到查找过程中，即find_library的实现里。搜寻单个library或者多个library实际上都会调用到find_libraries，只不过它们在调用函数时的参数会有所区别。

函数find_libraries也同样适用于隐式调用过程。它的处理过程比较复杂，主要分为5个核心步骤，其中与动态库加载操作有直接关联的是find_library_internal。后者首先会分析需要被加载的动态库是否在Public Namespace（g_public_namespace）中，如果是的话就表示目标对象已经加载成功了（因为这些公共库会被预先加载）；否则就通过load_library来定位并加载目标动态库。不过前提条件是程序通过了非法接口访问的检查，具体的判断逻辑如下所示：

- 如果NameSpace不是isolated的话，则有权限访问指定的library；
- 否则如果library在ld路径下，也有权限访问；
- 否则如果library在Default Library Paths目录中，也有权限访问；
- 否则如果library在Permitted Paths中，同样有权限访问；

- 除以上几种情况外，都无权访问指定的library。

一切准备就绪后，我们就可以通过dlsym来查找加载的动态库中是否包含JNI_OnLoad入口函数了。如前所述，JNI_OnLoad并非强制要求的，所以即便没有找到也不会产生致命问题。

为了帮助大家理解System.load的整个处理逻辑，我们特别提供下面的流程图，如图21-41所示。

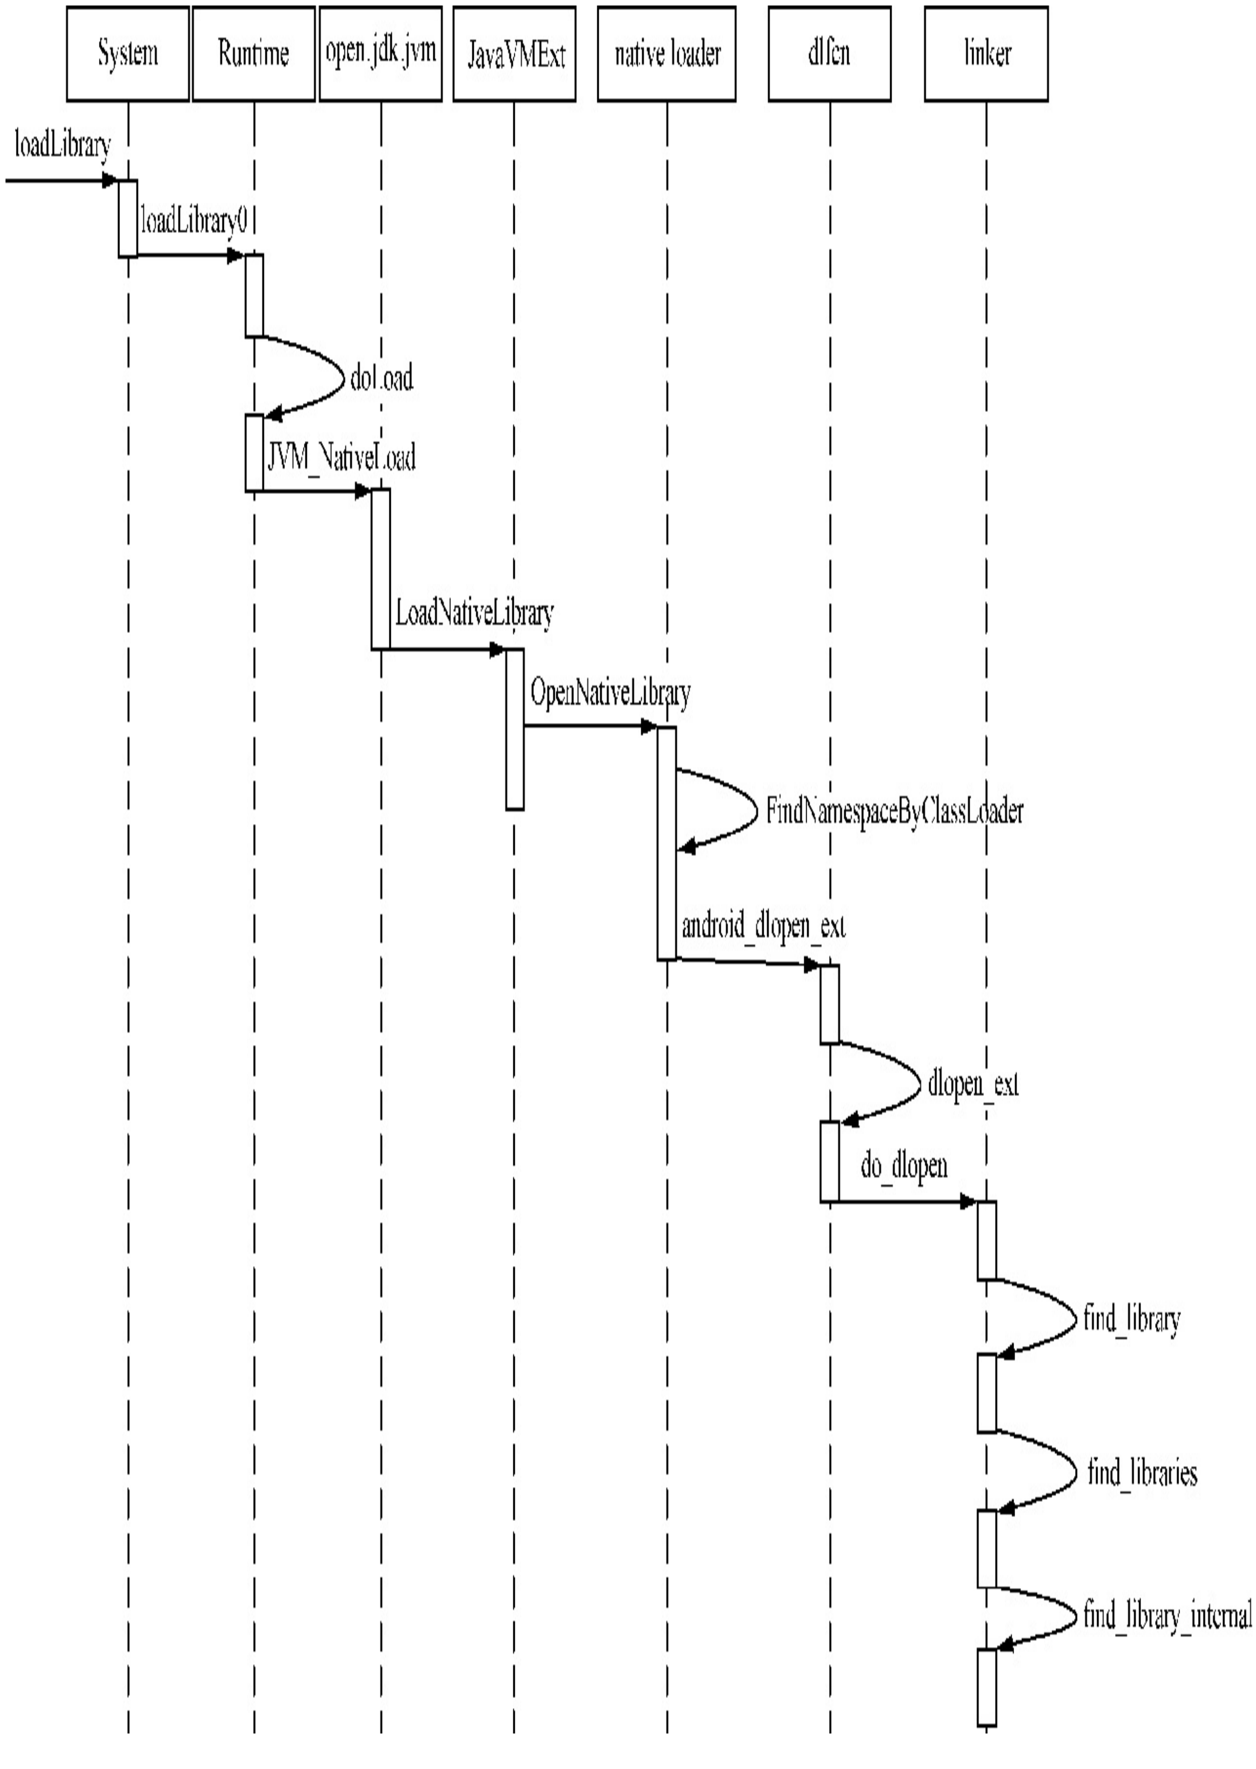
System
Runtime
open.jdk.jvm
JavaVMExt
native loader
dlfcn
linker
loadLibrary
loadLibrary0
doLoad
JVM_NativeLoad
LoadNativeLibrary
OpenNativeLibrary
FindNamespaceByClassLoader
android_dlopen_ext
dlopen_ext
do_dlopen
find_library
find_libraries
find_library_internal

▲图21-41　动态库的显式调用流程

理解了动态链接库的加载流程后，本小节的最后我们再进一步分析Java中声明为native的函数是如何与本地层中的具体实现建立起正确的映射关系的。这同时也是JNI所要解决的核心问题之一。通过前面内容的学习我们知道，JNI_OnLoad是动态链接库的“入口地址”，通常用于完成一些初始化操作（包括注册JNI函数）。譬如下面是从Android工程中摘取的其中一个典型范例：

```
/*frameworks/base/media/jni/android_media_MediaPlayer.cpp*/
jint JNI_OnLoad(JavaVM* vm, void* /* reserved */)
{
    JNIEnv* env = NULL;
    jint result = -1;
    …
    if (register_android_media_MediaPlayer(env) < 0) {
        ALOGE("ERROR: MediaPlayer native registration failed\n");
        goto bail;
    }
```

MediaPlayer的JNI_OnLoad实现中有很多register_XX_XX格式的注册函数，它们就是用于注册JNI函数的：

```
/*frameworks/base/media/jni/android_media_MediaPlayer.cpp*/
static int register_android_media_MediaPlayer(JNIEnv *env)
{
    return AndroidRuntime::registerNativeMethods(env,
                "android/media/MediaPlayer", gMethods, NELEM(gMet
}
```

Media Player通过AndroidRuntime:: registerNativeMethods来将JNI中的函数注册到虚拟机中，这个函数实际上是对jniRegisterNativeMethods的一个中转（在条件允许的情况下，JNI也可以直接调用jniRegisterNativeMethods），后者的实现如下：

```
/*libnativehelper/JNIHelp.cpp*/
extern "C" int jniRegisterNativeMethods(C_JNIEnv* env, const char
    const JNINativeMethod* gMethods, int numMethods)
{
    JNIEnv* e = reinterpret_cast<JNIEnv*>(env);
    ALOGV("Registering %s's %d native methods...", className, num
```

```
    scoped_local_ref<jclass> c(env, findClass(env, className));
    …
    if ((*env)->RegisterNatives(e, c.get(), gMethods, numMethods)
        char* msg;
        asprintf(&msg, "RegisterNatives failed for '%s'; aborting
        e->FatalError(msg);
    }

    return 0;
}
```

变量env是一个JNIEnv对象，它是在JNI_OnLoad中通过JavaVM获取到的，而且是线程独立的：

```
/*art/runtime/jni_internal.cc*/
static jint RegisterNatives(JNIEnv* env, jclass java_class, const
                           methods, jint method_count) {
    return RegisterNativeMethods(env, java_class, methods, method
  }

  static jint RegisterNativeMethods(JNIEnv* env, jclass java_clas
JNINativeMethod* methods, jint method_count, bool return_errors)
    CHECK_NON_NULL_ARGUMENT_FN_NAME("RegisterNatives", java_class
    ScopedObjectAccess soa(env);
    mirror::Class* c = soa.Decode<mirror::Class*>(java_class);
    …
    CHECK_NON_NULL_ARGUMENT_FN_NAME("RegisterNatives", methods, J
    for (jint i = 0; i < method_count; ++i) {
      const char* name = methods[i].name;
      const char* sig = methods[i].signature;
      const void* fnPtr = methods[i].fnPtr;
      …
      bool is_fast = false;
      if (*sig == '!') {
        is_fast = true;
        ++sig;
      }

      ArtMethod* m = nullptr;
      bool warn_on_going_to_parent =
      down_cast<JNIEnvExt*>(env)->vm->IsCheckJniEnabled();
      for (mirror::Class* current_class = c;
           current_class != nullptr;
           current_class = current_class->GetSuperClass()) {
        // Search first only comparing methods which are native.
        m = FindMethod<true>(current_class, name, sig);
        if (m != nullptr) {
```

```
        break;
      }

      // Search again comparing to all methods, to find non-nat
      m = FindMethod<false>(current_class, name, sig);
      if (m != nullptr) {
        break;
      }
    }
    …
    m->RegisterNative(fnPtr, is_fast);
  }
  return JNI_OK;
}
```

注册过程的目的是建立Java函数与Native函数之间的对应关系，因此不难推断出Register NativeMethods首先要解决的问题是如何查找到Class类（即java_class）中的Java层函数。另外，RegisterNativeMethods面对的并非单个函数，而是一个函数集合methods。集合中的每个元素都是JNINativeMethod对象，它们包含了Java函数名，Signature（将Java函数的返回值和参数表述成字符串的一种方式）以及native函数原型，范例如下：

```
{"_setDataSource","(Ljava/io/FileDescriptor;JJ)V", (void *)androi
```

以Media Player中这个例子来说，需要查找的是名为_setDataSource的Java函数，它的Signature则是“(Ljava/io/FileDescriptor;JJ)V”。Art虚拟机中要查找的是一个ArtMethod对象，并由FindMethod负责。FindMethod我们后续还会有详细分析，这里只要知道它的职责就可以了。

查找到ArtMethod后，我们可以直接调用它的RegisterNative来完成注册工作。ArtMethod内部有两个配套的接口函数SetEntryPoint和GetEntryPoint，它们分别用于设置和读取这个ArtMethod的“入口代码”。换句话说，RegisterNative所要做的就是将Native Method在内存中的地址通过SetEntryPoint设置为对应ArtMethod的“JNI入口”；在JNI的环境下，当Java层中的函数被调用后，首先会找到它的ArtMethod对象，然后通过GetEntryPoint得到JNI入口代码的地址。

这样就成功地完成Java层函数与Native层函数的JNI映射了。

21.3.4 Signal Handler和Fault Manager

从Linux操作系统的角度来看，Android虚拟机可以理解为它的一个应用程序，因而Linux的信号处理机制在虚拟机中也同样适用。

Art虚拟机中有一个专门处理异常信号的“总管”，名为fault_manager。它会在Runtime::init中进行同步初始化，如下所示：

```
/*art/runtime/runtime.cc*/
if (!no_sig_chain_) {//由虚拟机参数决定，通常只有在dex2oat时才会要求不启
    InitializeSignalChain();

    if (implicit_null_checks_ || implicit_so_checks_ || implicit_
      fault_manager.Init();
      if (implicit_suspend_checks_) {
        new SuspensionHandler(&fault_manager);
      }

      if (implicit_so_checks_) {
        new StackOverflowHandler(&fault_manager);
      }

      if (implicit_null_checks_) {
        new NullPointerHandler(&fault_manager);
      }

      if (kEnableJavaStackTraceHandler) {
        new JavaStackTraceHandler(&fault_manager);
      }
    }
  }
```

InitializeSignalChain简单来说只做了两件事情，即：

```
dlsym(RTLD_NEXT, "sigaction");
dlsym(RTLD_NEXT, "sigprocmask");
```

RTLD_NEXT是一个特殊的句柄参数，表示查找链接库中的“下一个”目标符号出现的地方。它的典型使用场景是程序希望自定义一个新的函数来代替原先库中的实现（有点类似于Hook）。例如，上述的sigaction和sigprocmask都是libc库中的固有函数，而Android虚拟机的信号处理子系统对它们的功能有所改进，这时候就可以使用LD_PRELOAD来保证同名新函数所在库（即libsigchain）优先得到加

载，并且利用RTLD_NEXT来寻找到原先的老函数（分别记录到全局变量linked_sigaction_sym和linked_sigprocmask_sym中）。另外，libsigchain需要通过LOCAL_WHOLE_STATIC_LIBRARIES链接到app_process中。

FaultManager在初始化过程中会利用Linux提供的signal机制来建立信号处理机制：

```
/*art/runtime/fault_manager.cc*/
void FaultManager::Init() {
  CHECK(!initialized_);
  struct sigaction action;
  SetUpArtAction(&action);//

  int e = sigaction(SIGSEGV, &action, &oldaction_);
  if (e != 0) {
    VLOG(signals) << "Failed to claim SEGV: " << strerror(errno);
  }
  // Make sure our signal handler is called before any user handl
  ClaimSignalChain(SIGSEGV, &oldaction_);
  initialized_ = true;
}
```

上述的代码段逻辑是：首先创建一个sigaction对象（注意：这里的sigaction是一个struct结构，要与后续的sigaction函数区分开来），然后通过SetUpArtAction来对其进行设置。紧接下来的sigaction理论上是Linux提供的用于登记信号处理函数的API——但是大家应该要清楚这个函数已经被libsigchain中提供的新函数替换掉了，新函数的实现如下：

```
/*art/sigchainlib/sigchain.cc*/
extern "C" int sigaction(int signal, const struct sigaction* new_
  if (signal > 0 && signal < _NSIG && user_sigactions[signal].IsC
      (new_action == nullptr || new_action->sa_handler != SIG_DFL
    struct sigaction saved_action = user_sigactions[signal].GetAc
    if (new_action != nullptr) {
      user_sigactions[signal].SetAction(*new_action, false);
    }
    if (old_action != nullptr) {
      *old_action = saved_action;
    }
    return 0;
  }
```

```
  if (linked_sigaction_sym == nullptr) {
    InitializeSignalChain();
  }

  if (linked_sigaction_sym == nullptr) {
    log("Unable to find next sigaction in signal chain");
    abort();
  }
  SigActionFnPtr linked_sigaction =
reinterpret_cast<SigActionFnPtr>(linked_sigaction_sym);
  return linked_sigaction(signal, new_action, old_action);
}
```

那么llibsigchain截获sigaction函数的目的是什么呢？

在计算机安全领域，Hacker们也经常会通过截获函数（参考本书安全章节的详细分析）来提取一些重要的信息（或者完成自己期望的操作），而且还不能破坏原先的函数调用。这里的做法也是类似的——自定义的sigaction在截获原函数后，会将新的action记录到内部的user_sigactions数组中，然后再调用真正的sigaction函数（linked_sigaction）。这样做的目的是保证signal chain可以优先获得处理它感兴趣的信号的权利，而不会被上层用户自己定义的action所覆盖。当然，如果在实际处理信号的过程中出现signal chain“无能为力”的情况，那么此时我们也会综合考虑用户设置的action——这也是设计user_sigactions数组的初衷之一。另外，大家应该特别关注的是art_fault_handler，它会作为SIGSEGV信号的sa_sigaction传递给kernel，是FaultManager管理Handler的驱动力。

目前fault_manager最多管理4种Handler，它们分别用于处理不同的事件，并且全部继承自FaultHandler。各Handler在构造函数中会主动调用AddHandler来将自己添加到fault_manager的管理中。以Suspend Check为例，它的主要作用是实现线程挂起（可以参见后续的分析）。

当SIGSEGV信号发生时，kernel首先会调用静态函数art_fault_handler，后者则直接将信息传递给全局变量fault_manager来处理，如下所示：

```
/*art/runtime/fault_handler.cc*/
void FaultManager::HandleFault(int sig, siginfo_t* info, void* co
  if (IsInGeneratedCode(info, context, true)) {
    VLOG(signals) << "in generated code, looking for handler";
```

```
    for (const auto& handler : generated_code_handlers_) {
      VLOG(signals) << "invoking Action on handler " << handler;
      if (handler->Action(sig, info, context)) {…
      }
    }
    if (HandleFaultByOtherHandlers(sig, info, context)) {
        return;
    }
  }

  // Set a breakpoint in this function to catch unhandled signals
  art_sigsegv_fault();

  // Pass this on to the next handler in the chain, or the defaul
  InvokeUserSignalHandler(sig, info, context);
}
```

从上述代码段我们可以看出，事件处理的优先级顺序如下：

- generated_code_handlers_；
- other_handlers_，即HandleFaultByOtherHandlers；
- 用户自定义的处理，即InvokeUserSignalHandler。

前两个Handler数组都是在AddHandler时添加的，并且根据第二个参数generated_code来划分。下面我们重点分析最常见的情况，即针对generated_code_handlers_是如何处理的。

还是以Suspension Check为例，它的Action（arm平台）定义如下：

```
/*art/runtime/arch/arm/fault_handler_arm.cc*/
bool SuspensionHandler::Action(int sig ATTRIBUTE_UNUSED,
                   siginfo_t* info ATTRIBUTE_UNUSED, void* contex
  uint32_t checkinst1 = 0xf8d90000 +
                             Thread::ThreadSuspendTriggerOffset<4
  uint16_t checkinst2 = 0x6800;

  struct ucontext* uc = reinterpret_cast<struct ucontext*>(contex
  struct sigcontext *sc = reinterpret_cast<struct sigcontext*>(&u
  uint8_t* ptr2 = reinterpret_cast<uint8_t*>(sc->arm_pc);//事件发生
  uint8_t* ptr1 = ptr2 - 4;
  VLOG(signals) << "checking suspend";

  uint16_t inst2 = ptr2[0] | ptr2[1] << 8;
```

```
  VLOG(signals) << "inst2: " << std::hex << inst2 << " checkinst2
  if (inst2 != checkinst2) {
    return false;
  }
  uint8_t* limit = ptr1 - 40;   // Compiler will hoist to a max o
  bool found = false;
  while (ptr1 > limit) {
    uint32_t inst1 = ((ptr1[0] | ptr1[1] << 8) << 16) | (ptr1[2]
    VLOG(signals) << "inst1: " << std::hex << inst1 << " checkins
    if (inst1 == checkinst1) {
      found = true;
      break;
    }
    ptr1 -= 2;      // Min instruction size is 2 bytes.
  }
  if (found) {//当前是Suspend Check
    VLOG(signals) << "suspend check match";

    VLOG(signals) << "arm lr: " << std::hex << sc->arm_lr;
    VLOG(signals) << "arm pc: " << std::hex << sc->arm_pc;
    sc->arm_lr = sc->arm_pc + 3;      // +2 + 1 (for thumb)
    sc->arm_pc = reinterpret_cast<uintptr_t>(art_quick_implicit_s

    // Now remove the suspend trigger that caused this fault.
    Thread::Current()->RemoveSuspendTrigger();
    VLOG(signals) << "removed suspend trigger invoking test suspe
    return true;
  }
  return false;
}
```

在讲解action函数之前，我们先来补充一些背景知识。

当kernel回调用户空间的信号处理函数时，它首先会为本次事件准备必要的参数信息，其中就包括了sigcontext。这个数据结构中详细记录了事件发生时各个寄存器的状态（因而是平台相关的），以及错误码等内容。由于sigcontext.h属于kernel中的头文件，为了保证用户空间也可以正常使用它，Android系统特别将kernel层的原始头文件放置在AOSP工程的/external/kernel-headers里，并通过bionic/libc/kernel/tools/update_all.py来将它们自动编辑、改造成上层可用的头文件形式，并保存在\bionic\libc\kernel对应目录下。

如果是因为Suspension Check而引发的SIGSEGV，从前面的描述可知Thread::suspend_trigger必定为nullptr。那么我们如何检查当前的

信号事件是访问了suspend_trigger这个nullptr触发的呢？答案就是通过sigcontext结构体。

另外，我们还可以进一步思考的是，程序是在什么时候调用的Thread::suspend_trigger，对应的机器指令是什么？

以arm平台为例，就是如下所示的指令序列：

```
// 0xf723c0b2: f8d902c0  ldr.w   r0, [r9, #704]  ; suspend_trigge
// .. 一些中间过程
// 0xf723c0b6: 6800      ldr     r0, [r0, #0]
```

其中第一行表示加载Thread::suspend_trigger（在虚拟机的调用约束中，r9代表当前线程）指针，而最后一行（两者地址差为4）就是去取指针所指向的内容——可想而知，这就是引发SIGSEGV的地方。

这样一来就不难理解SuspensionHandler::Action函数的处理逻辑了：指针ptr1和ptr2就分别对应着指令序列的首尾，所以我们要做的就是比较它们所指位置的指令是否和预想的一致，从而判断出本次事件的“触发源”。

如果确认的结果是Suspension Check，那么接下来程序会调用art_quick_implicit_suspend来执行线程挂起事件（后续小节已经有详细分析，这里先不赘述），并通过RemoveSuspendTrigger来避免后续再因此产生SIGSEGV。

假如signal chain没有办法处理当前事件，那么它会进一步通过InvokeUserSignalHandler来将控制权传递给用户注册的事件处理函数，此时就需要使用到user_sigactions数组。而如果User Action也无法处理这一事件，那么InvokeUserSignalHandler将通过signal系统调用（第二个参数设置为SIG_DFL）来保证事件可以被以系统默认的方式进行处理。

值得一提的是，Android提供了一个名为dubuggerd的daemon来负责所有程序的crash事件，大家所熟知的tombstone文件就是由它产生的。因为debuggerd是作为Server端存在的，它需要程序在crash时主动与之取得联系。扮演这个Client角色的模块就存在于Linker中，后者也会利用Linux的信号处理机制来注册自己感兴趣的信号，并在适当的时机将消息报告给debuggerd，以便这个全局daemon程序可以及时记录系统中

发生的crash问题，为开发人员定位和解决问题提供必要的辅助信息。

21.4 Android虚拟机核心文件格式——“主宰者”OAT

经过前面几个小节的知识铺垫，现在我们可以正式进入Art虚拟机中OAT的学习了。

21.4.1 OAT文件格式解析

与OAT相关的文件后缀有如下几种：

- .art

在Android M版本中只有一个，即boot.art，存储路径在/system/framework/oat或者/data/dalvik- cache/中。这个文件也被称为image，是由dex2oat工具生成的。它的内部包含了很多Dex文件，Zygote在启动过程中会加载boot.art。

在Android N版本中，因为Application也可以有image，所以情况会稍有不同。

- .oat

OAT是由dex2oat产生的。不少读者会有这样的疑问，即boot.art和boot.oat有什么区别和联系呢？如果我们把boot.oat比作一个exe文件的话，那么boot.art则类似于exe程序的运行时实例。因为boot.art中包含了很多已经预初始化了的类和对象，这样无疑可以加快启动速度（但同时也会带来10MB左右的额外空间占用）。关于它们二者之间的联系，本小节后续内容中还有更多详细讲解。

- .odex

在Dalvik中，odex表示被优化后的Dex文件；Art虚拟机中也同样存在odex文件，但和Dalvik中的情况不同，它们实际上也是.oat文件。

很显然dex2oat会耗费一定的时间（特别是当系统第一次开机时，或者是恢复了出厂设置后，此时会对所有的用户应用程序进行重新编译），因而我们可以将一部分编译工作以预优化（pre-optimized）的方式在ROM构建时完成；这种做法的一个缺点是会占用System分区额外

的存储空间——所以我们希望在这二者间寻求一种平衡。Android系统特别提供了如下编译选项供开发人员选择：

- （1）WITH_DEXPREOPT

是否开启预优化开关，在Android LolliPop之前编译user版本时是默认打开的；而Android L版本之后需要在BoardConfig.mk中主动打开。这个开关是后续几个含有“PREOPT”开头的选项的基础，它表示system image中的所有对象（例如apk、jar文件等）都需要被执行预优化。

- （2）DONT_DEXPREOPT_PREBUILTS

Prebuilt的程序不希望参加预优化，此时可以使用这个选项。使用范例：

```
WITH_DEXPREOPT := true
DONT_DEXPREOPT_PREBUILTS := true
```

- （3）WITH_DEXPREOPT_BOOT_IMG_ONLY

除了boot image外，其他所有对象都不参加预优化。使用范例：

```
WITH_DEXPREOPT := true
WITH_DEXPREOPT_BOOT_IMG_ONLY := true
```

- （4）LOCAL_DEX_PREOPT

对象可以单独指定自己是否参加预优化。这个选项支持“true”“false”和“nostripping”（表示不把classes.dex从apk或者jar文件中剔除）等值。

在Dalvik虚拟机时代，与系统framework相关联的odex会保存在设备的/system/framework子文件夹中；Art虚拟机则略有差异，它将这些文件（包括boot.art和boot.oat）统一保存到/system/framework/arm（或者arm64）中，示例如图21-42所示。

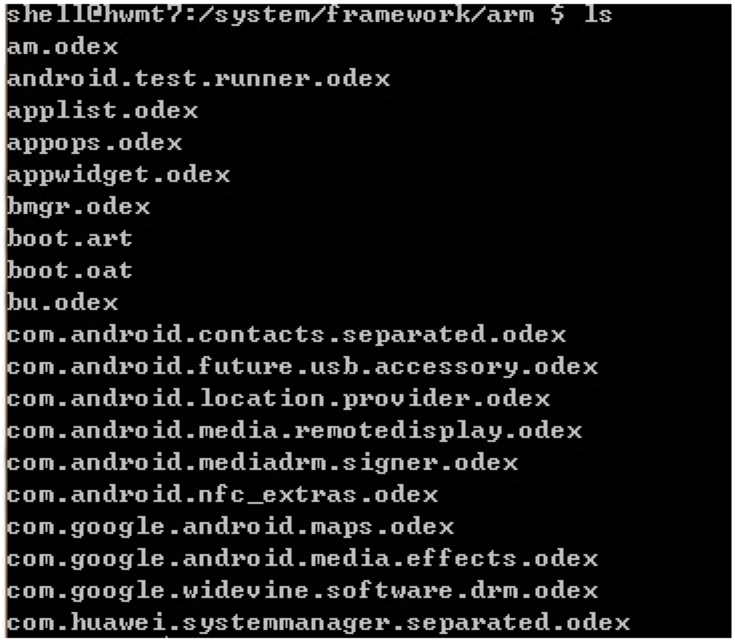

▲图21-42 Art虚拟机中odex和oat文件的存储路径

需要特别注意的是，即便是我们预先在System分区中生成了odex文件，系统还是会在Data分区中产生对应的Dex文件。而且odex和Dex事实上都是OAT文件，那么为什么需要两份呢？简单来说Dex是由Odex文件加上一个偏移量（对于每个设备来说是随机的）得到的，原因是为了系统的安全性着想，因为如果所有设备都采用同一个固定地址容易遭受非法攻击。

OAT并没有什么神秘的，它本质上也属于前面小节中我们介绍的ELF文件，具体关系如图21-43所示。

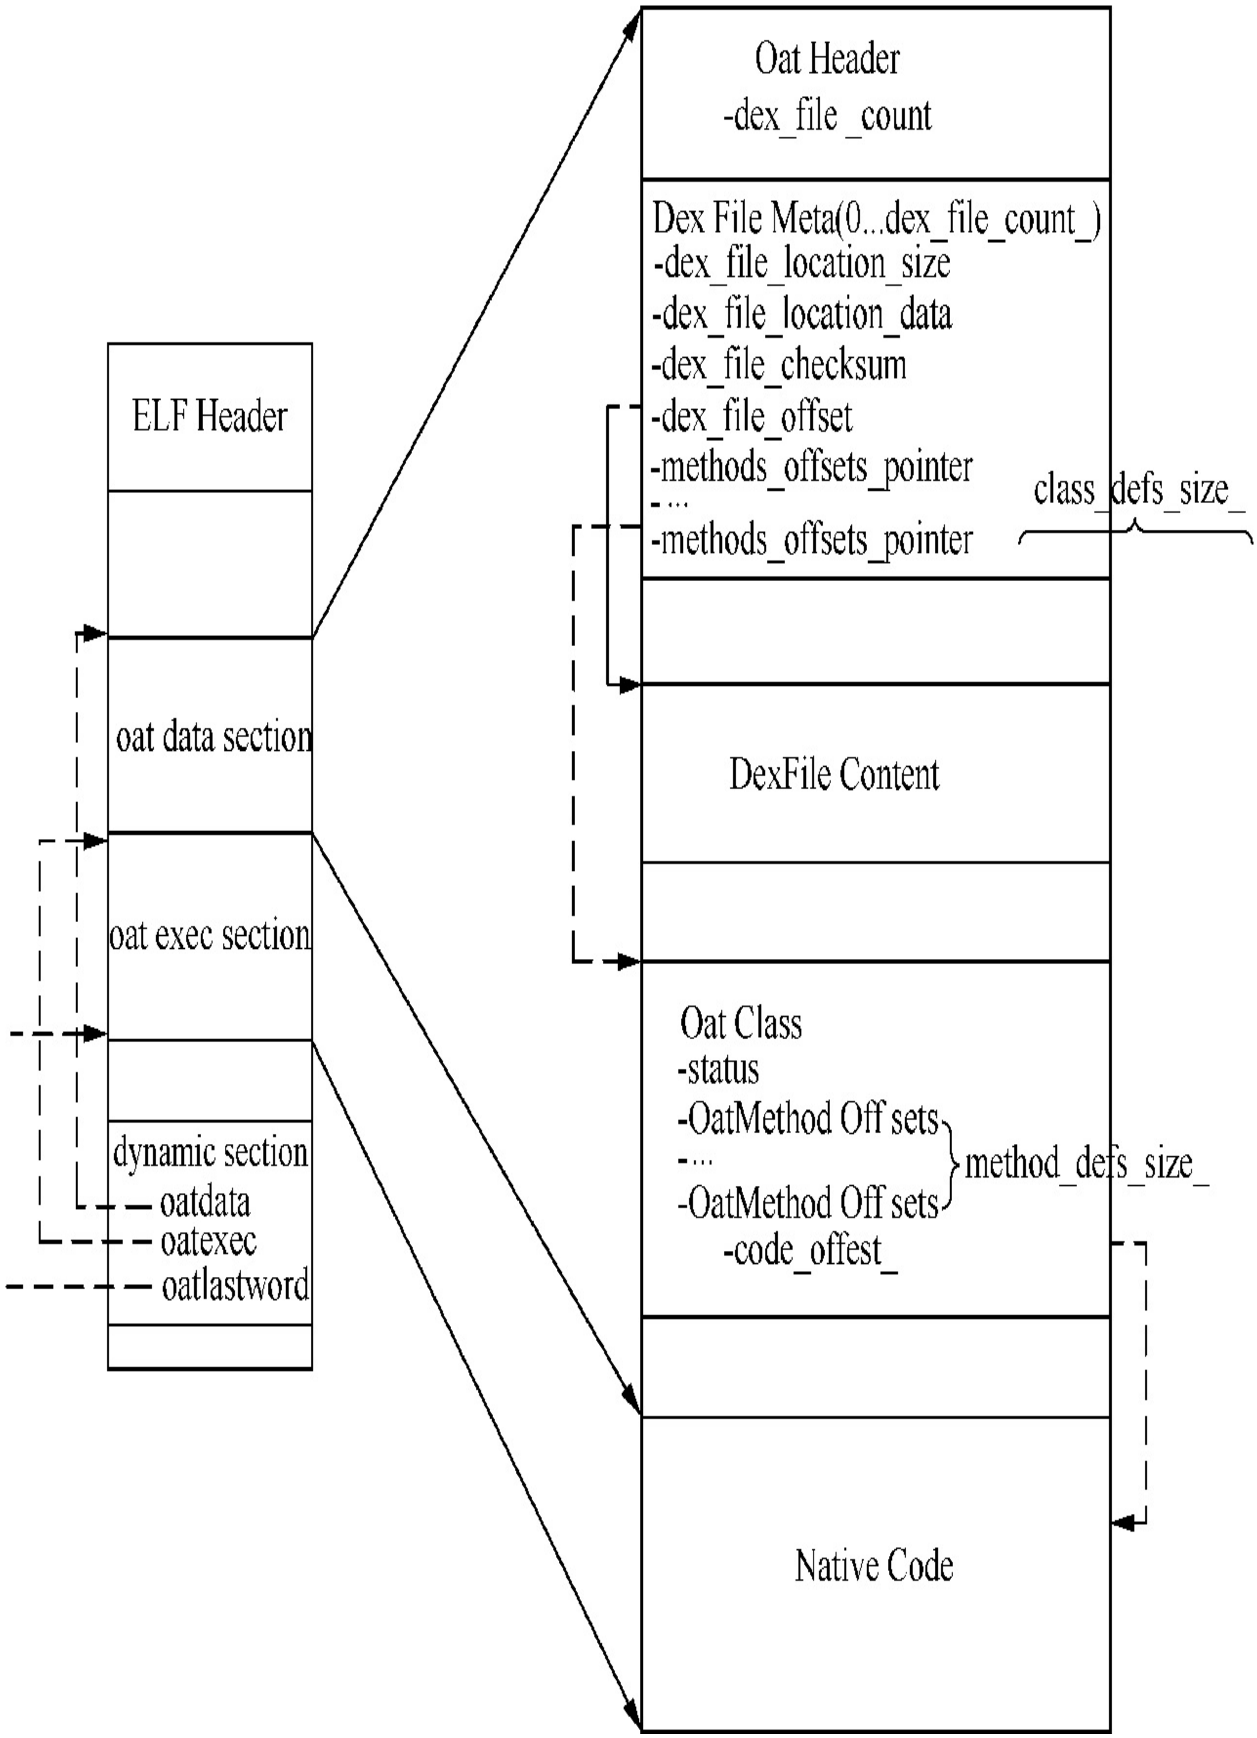

ELF Header
oat data section
oat exec section
dynamic section
oatdata
oatexec
oatlastword
Oat Header
-dex_file _count
Dex File Meta(0...dex_file_count_)
-dex_file_location_size
-dex_file_location_data
-dex_file_checksum
-dex_file_offset
-methods_offsets_pointer
-...
-methods_offsets_pointer
class_defs_size_
DexFile Content
Oat Class
-status
-OatMethod Off sets
-...
-OatMethod Off sets
method_defs_size_
-code_offest_
Native Code

▲图21-43 OAT文件与elf文件之间的联系（引用自2014年Google I/O上的演示文档）

由Google I/O大会上披露的OAT文件格式图可知，OAT既遵循ELF文件规范，同时又根据虚拟机的实际需求进行了扩展——最大的区别在于它添加了两个重要的区段，即“Oat Data Section”和“Oat Exec Section”。其中“Data Section”保存的是原Dex文件中的字节码数据，而“Exec Section”则是Dex经过dex2oat翻译后生成的机器代码（Native Code）的存储区域。并且我们可以从Data Section中通过一定的对应关系可以迅速找到某个Class/Function在Exec Section中的机器码。

接下来我们通过剖析一个真实的OAT文件来加深大家的理解。这个例子在AOSP工程中的out目录下，即/out/target/product/generice/symbols/system/framework/arm/boo
我们可以对它执行readelf操作，显示结果如下所示：

```
ELF Header:
  Magic:   7f 45 4c 46 01 01 01 03 00 00 00 00 00 00 00 00
  Class:                             ELF32
  Data:                              2's complement, little endian
  Version:                           1 (current)
  OS/ABI:                            UNIX - GNU
  ABI Version:                       0
  Type:                              DYN (Shared object file)
  Machine:                           ARM
  Version:                           0x1
  Entry point address:               0x0
  Start of program headers:          52 (bytes into file)
  Start of section headers:          53679876 (bytes into file)
  Flags:                             0x5000000, Version5 EABI
  Size of this header:               52 (bytes)
  Size of program headers:           32 (bytes)
  Number of program headers:         5
  Size of section headers:           40 (bytes)
  Number of section headers:         9
  Section header string table index: 8

Section Headers:
  [Nr] Name              Type            Addr     Off    Size   ES Flg Lk Inf Al
  [ 0]                   NULL            00000000 000000 000000 00      0   0  0
  [ 1] .dynsym           DYNSYM          70945134 000134 000040 10   A  2   0  4
  [ 2] .dynstr           STRTAB          70945174 000174 000026 00   A  0   0  1
  [ 3] .hash             HASH            7094519c 00019c 000020 04   A  1   0  4
  [ 4] .rodata           PROGBITS        70946000 001000 1d10000 00   A  0   0 4096
  [ 5] .text             PROGBITS        72656000 1d11000 15daab0 00  AX  0   0 4096
  [ 6] .dynamic          DYNAMIC         73c31000 32ec000 000038 08   A  2   0 4096
  [ 7] .text.oat_patches LOUSER+0        00000000 32ec038 045681 00      0   0  1
  [ 8] .shstrtab         STRTAB          00000000 33316b9 00004a 00      0   0  1
Key to Flags:
```

由上图可知，boot.oat确实是一个ELF格式的文件，并且包含了多个.text相关的字段。那么Oat Data Section和Oat Exec Section具体对应哪些区段呢？

```
Symbol table '.dynsym' contains 4 entries:
   Num:    Value  Size Type    Bind   Vis      Ndx Name
     0: 00000000     0 NOTYPE  LOCAL  DEFAULT  UND
     1: 70946000 0x1d10000 OBJECT  GLOBAL DEFAULT    4 oatdata
     2: 72656000 0x15daab0 OBJECT  GLOBAL DEFAULT    5 oatexec
     3: 73c30aac     4 OBJECT  GLOBAL DEFAULT    5 oatlastword
```

这个问题的答案可以从“.dynsym”——DYNSYM类型的动态符号表中找到。与Data和Exec Section相关联的有3个重要变量，即oatdata、oatexec和oatlastword。其中oatdata指向的是Oatdata Section的起始地址；而oatexec指向的是Oatexec Setion的起始地址——翻译后的机器指令保存在这个区域。另外一个符号oatlastword则用于指示Oatexec Setion的结束地址。因为Data和Exec两个区域是紧挨着的，所以，[oatdata,oatexec]自然就是Dex的存储范围，同时[oatexec,oatlastword]就是机器指令的存储区域了。

这些知识点我们从加载OAT文件的Dlopen函数中也同样可以得到印证，核心源码如下所示：

```
/*art/runtime/oat_file.cc*/
bool OatFile::Dlopen(const std::string& elf_filename, byte* reque
                 std::string* error_msg) {
  char* absolute_path = realpath(elf_filename.c_str(), NULL);
  if (absolute_path == NULL) {
*error_msg = StringPrintf("Failed to find absolute path for '%s'"
                           elf_filename.c_str());
    return false;
  }
  dlopen_handle_ = dlopen(absolute_path, RTLD_NOW);
  free(absolute_path);
  if (dlopen_handle_ == NULL) {
    *error_msg = StringPrintf("Failed to dlopen '%s': %s", elf_fi
                               dlerror());
    return false;
  }
  begin_ = reinterpret_cast<byte*>(dlsym(dlopen_handle_, "oatdata
  if (begin_ == NULL) {
    *error_msg = StringPrintf("Failed to find oatdata symbol in '
elf_filename.c_str(),dlerror());
    return false;
  }
  if (requested_base != NULL && begin_ != requested_base) {
    *error_msg = StringPrintf("Failed to find oatdata symbol at e
                         "oatdata=%p != expected=%p /proc/self/ma
                         begin_, requested_base);
    ReadFileToString("/proc/self/maps", error_msg);
    return false;
  }
  end_ = reinterpret_cast<byte*>(dlsym(dlopen_handle_, "oatlastwo
  if (end_ == NULL) {
    *error_msg = StringPrintf("Failed to find oatlastword symbol 
elf_filename.c_str(),dlerror());
```

```
    return false;
  }
  // Readjust to be non-inclusive upper bound.
  end_ += sizeof(uint32_t);
  return Setup(error_msg);
}
```

上面这段代码的逻辑是：首先获取ELF（oat）文件的绝对路径，然后通过dlopen这个API打开它，文件句柄则保存在dlopen_handle_变量中。接着两次调用dlsym函数，分别查找到“oatdata”和“oatlastword”这两个Dynamic Symbol，并将它们保存到全局变量begin_和end_中。有了这两个变量，当然就可以确定oatdata和oatexec两个区段的起止地址了。最后再调用Setup来进入下一步的工作。

Setup函数比较长，我们重点关注与OAT文件格式相关的内容：

```
/*art/runtime/oat_file.cc*/
bool OatFile::Setup(std::string* error_msg) {
  if (!GetOatHeader().IsValid()) {//检查OAT文件的magic number,版本等
    *error_msg = StringPrintf("Invalid oat magic for '%s'", GetLo
    return false;
  }
  const byte* oat = Begin(); //获取begin_全局变量的值，即oatdata
  oat += sizeof(OatHeader); //跳过OatHeader所占空间
  if (oat > End()) {//End()返回end_全局变量的值，即oatlastword
    *error_msg = StringPrintf("In oat file '%s' found truncated O
                              GetLocation().c_str());
    return false;
  }

  oat += GetOatHeader().GetKeyValueStoreSize();
  if (oat > End()) {//OAT文件大小异常
    …
    return false;
  }

  uint32_t dex_file_count = GetOatHeader().GetDexFileCount();//OA
  oat_dex_files_storage_.reserve(dex_file_count);
  for (size_t i = 0; i < dex_file_count; i++) {
    uint32_t dex_file_location_size = *reinterpret_cast<const uin
                                                       //Dex文件路径
    …
    oat += sizeof(dex_file_location_size);//跳过文件路径字符串所占的空
    …
```

```
    const char* dex_file_location_data = reinterpret_cast<const c
                      //Dex文件路径
    oat += dex_file_location_size;
    …
    std::string dex_file_location(dex_file_location_data, dex_fil

    uint32_t dex_file_checksum = *reinterpret_cast<const uint32_t
    oat += sizeof(dex_file_checksum);//Dex文件的校验码
    …
    uint32_t dex_file_offset = *reinterpret_cast<const uint32_t*>
                 //Dex文件的偏移量
    …
    oat += sizeof(dex_file_offset);
    …
    const uint8_t* dex_file_pointer = Begin() + dex_file_offset;
                     //Dex 文件的起始地址，注意它是在dex_file_offset的
    /*Dex的合法性检查*/
    if (UNLIKELY(!DexFile::IsMagicValid(dex_file_pointer))) {…
      return false;
    }
    if (UNLIKELY(!DexFile::IsVersionValid(dex_file_pointer))) {…
      return false;
    }
    const DexFile::Header* header =
           reinterpret_cast<const DexFile::Header*>(dex_file_poin
    const uint32_t* methods_offsets_pointer = reinterpret_cast<co

    oat += (sizeof(*methods_offsets_pointer) * header->class_defs
    …
    OatDexFile* oat_dex_file = new OatDexFile(this, dex_file_loca
                                  canonical_location, dex_fil
                                  dex_file_pointer,methods_of
    oat_dex_files_storage_.push_back(oat_dex_file);

    // Add the location and canonical location (if different) to
    StringPiece key(oat_dex_file->GetDexFileLocation());
    oat_dex_files_.Put(key, oat_dex_file);
    if (canonical_location != dex_file_location) {
      StringPiece canonical_key(oat_dex_file->GetCanonicalDexFile
      oat_dex_files_.Put(canonical_key, oat_dex_file);
    }
  }
  return true;
}
```

这个函数为我们很好地描绘出了OAT文件格式的全景图。相信大家在一行行阅读代码的同时，OAT的整体框架就已经在脑海中形成了。

首先，我们通过GetOatHeader().IsValid()来判断当前的OAT文件是否合法。检查项包括文件的魔数是否为“oat”；版本号是否等于“039”；是否页对齐等。GetOatHeader实际上就是将begin_变量所指向的地址做了一次OatHeader的强制类型转换。这里要提醒大家注意区分Elf Header和Oat Header这两个格式头——它们分别代表ELF文件格式的头部以及Art虚拟机中可执行文件（oat）的头部，而且后者“潜伏”于前者之中。

如果合法性检查没有问题的话，那么紧接着我们就可以利用Begin()返回的begin_全局变量来得到OAT区域的起始点（这也是“全景图”的起点）。随后OAT变量跳过OatHeader所占的空间大小。此时如果OAT已经超过end_，则表示文件出现了异常，此时函数将直接返回false值。

和Apk中的情况类似，OAT中也可能有不止一个Dex文件，具体数量可以通过GetDexFile Count获取到。对于每一个DexFile，我们都需要把它们逐一从OAT文件中“抠”出来，实现统一的管理。因而Setup函数需要通过一个for循环来完成对这些Dex的处理。这同时也要求OAT在存储这些Dex数据时一定得采用一种固定的格式——具体而言，dex_file_location_size占用sizeof(uint32_t)的空间大小，代表了Dex文件路径字符串所占的空间大小。指针OAT在起始时指向的是第一个Dex文件信息所在地，接着它读取Dex文件路径名所占空间大小保存到dex_file_location_size变量中，以及路径字符串所在位置dex_file_location_data，并由此组成dex_file_location字符串对象。紧随dex_file_location_data之后的是dex_file_checksum，即Dex文件的校验和，这个变量在创建OatDexFile时会派上用场。完成了这些变量的计算后，Dex文件的基本信息就比较清楚了。那么Dex文件的具体内容存储在OAT文件中的哪个位置呢？这就是dex_file_offset变量所承担的角色。如其名所示，它代表的是Dex File在OAT中的偏移量。所以存储Dex文件内容的起始地址应该是dex_file_pointer = Begin() + dex_file_offset。得到了Dex文件的起始地址后，我们需要先通过DexFile::IsMagicValid和IsVersionValid来确保这个Dex文件的合法性。IsMagicValid会读取并确保文件的魔数是否为“Dex”，而IsVersionValid则负责检查该Dex文件的版本号是否为“035”。

Dex文件同样提供了一个头部信息，即DexFile::Header。要特别注意此时OAT变量仍然指向dex_file_offset结束的位置，紧随其后的变量

是methods_offsets_pointer。通常情况下Dex文件中都包含了非常多的Class和各种成员函数，这些信息都保存在OAT文件中。

```
oat += (sizeof(*methods_offsets_pointer) * header->class_defs_siz
```

上面这条语句用于跳过Dex文件的函数信息段，其中methods_offsets_pointer指向的是某个函数在Dex Content中的具体实现；函数的总数量则是header->class_defs_size_。最后，我们创建一个OatDexFile对象来容纳Dex文件，并将结果统一保存到oat_dex_files_storage_和oat_dex_files_中——前者是std::vector类型的全局变量，用于保存所有Dex File；后者负责为DexFile和它的路径建立map关联。

OatDexFile对象保存了Dex文件的所有属性和内容数据，这些信息将在OAT的运行过程中发挥重要作用。OatDexFile的构造函数如下所示：

```
/*art/runtime/oat_file.cc*/
OatFile::OatDexFile::OatDexFile(const OatFile* oat_file,
                                const std::string& dex_file_location,
                                const std::string& canonical_dex_file_
                                uint32_t dex_file_location_checksum,
                                const byte* dex_file_pointer,
                                const uint32_t* oat_class_offsets_poin
    : oat_file_(oat_file),
      dex_file_location_(dex_file_location),
      canonical_dex_file_location_(canonical_dex_file_location),
      dex_file_location_checksum_(dex_file_location_checksum),
      dex_file_pointer_(dex_file_pointer),
      oat_class_offsets_pointer_(oat_class_offsets_pointer) {}
```

其中oat_file代表的是OAT文件，也就是前面setup函数中的this指针所指向的对象；oat_class_offsets_pointer对应的是setup中的methods_offsets_pointer（这个名字容易引起误解，大家特别注意），代表的是一个Oat Class的偏移地址。

我们知道，一个OAT中包含N个（N可能不止一个）Dex文件，而每个Dex中又包含N个Class，每个Class则又包含N个函数。

可能读者会有疑问，既然Art已经将Dex提前编译成OAT文件，那么为什么还要保留原始的Dex呢？Art如此设计主要基于如下几点考虑：

（1）为了提供一个便利的Class到Native Code的对应关系，从而加速代码的执行时间。关于这点我们在后续讲解代码的运行流程时还有更详细的分析。

（2）为开发者的调试过程提供更准确的源码定位。

（3）我们在很多情况下仍然需要依靠interpreter解析字节码的方式来执行应用程序。

通过上面的分析，相信大家对于OAT文件已经有了全局的认识了。我们再来通过图21-44做一下总结，大家可以看一下是否和脑海中绘制的结构图完全一致。

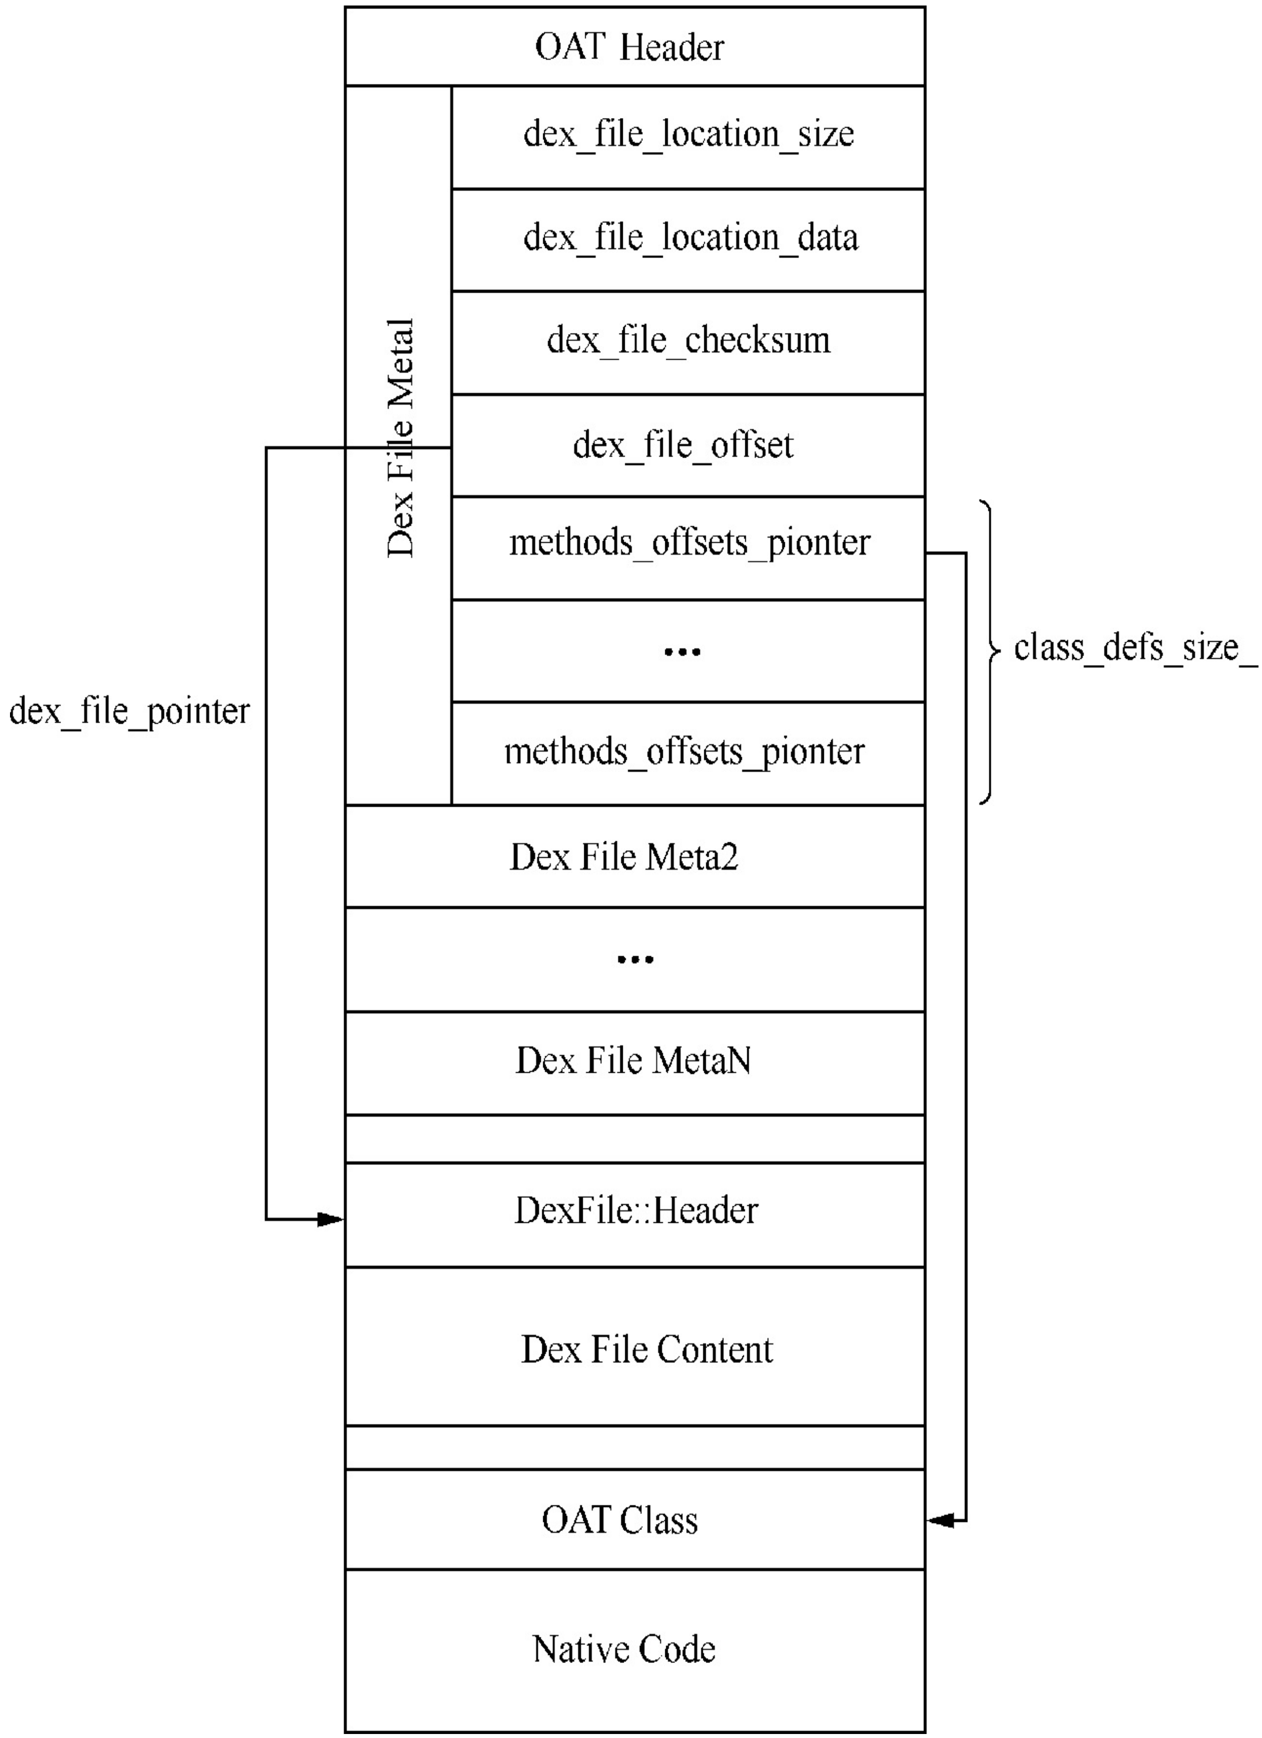
OAT Header
Dex File Metal
dex_file_location_size
dex_file_location_data
dex_file_checksum
dex_file_offset
methods_offsets_pionter
...
methods_offsets_pionter
class_defs_size_
dex_file_pointer
Dex File Meta2
...
Dex File MetaN
DexFile::Header
Dex File Content
OAT Class
Native Code

▲图21-44　OAT文件结构（1/2）

理解了OAT文件的内部结构后，我们再深入地解答一下本小节开头提到的问题，即boot.art和boot.oat之间的联系。

Boot.art简单来说是“An image file with a heap of preinitialized classes and objects”。它和boot.oat都存储在/system/framework/<isa>/文件夹下。根据Art虚拟机的设计，Boot.art和boot.oat之间是可以相互引用的，而且它们在内存中的加载位置是紧挨着的。图21-45是根据art/runtime/image.h文件总结出来的结构图。

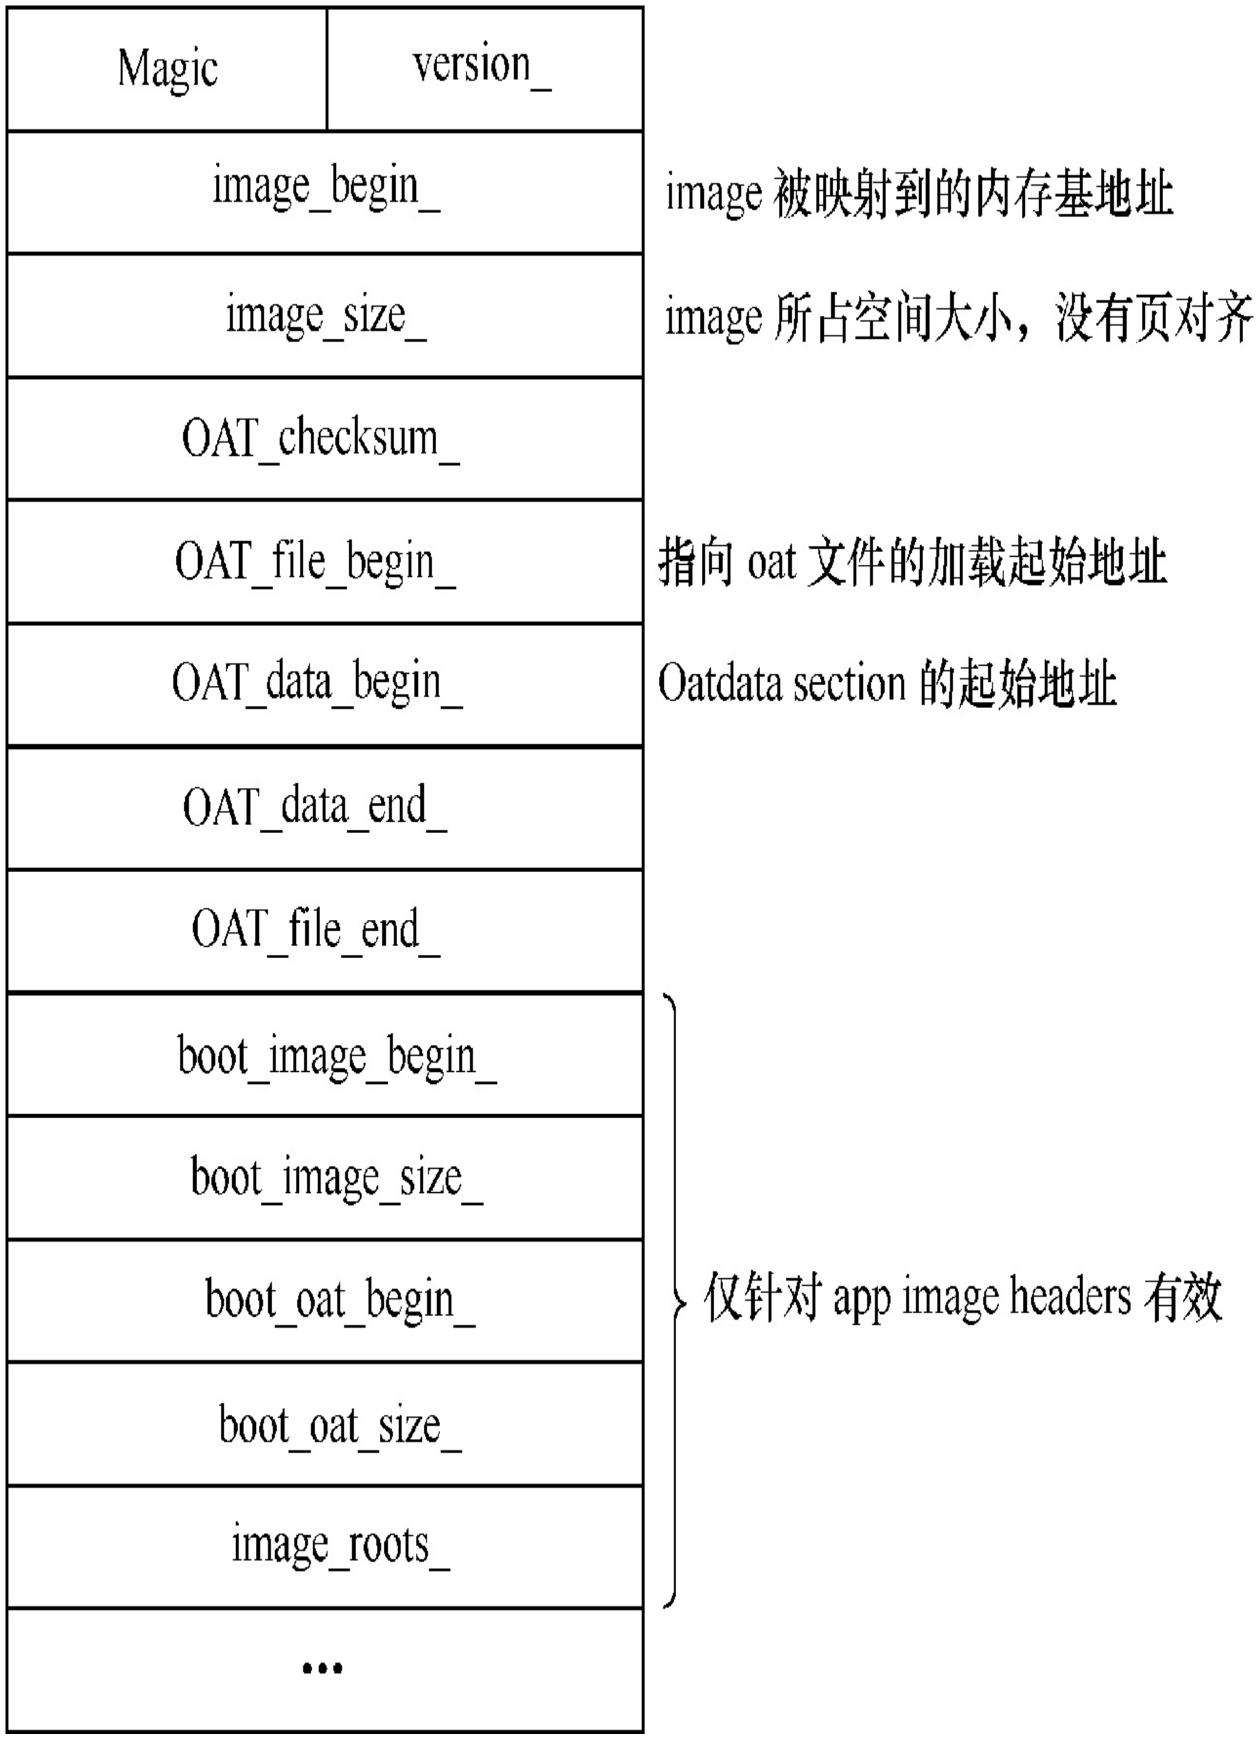

Magic
version_
image_begin_
image 被映射到的内存基地址
image_size_
image 所占空间大小，没有页对齐
OAT_checksum_
OAT_file_begin_
指向 oat 文件的加载起始地址
OAT_data_begin_
Oatdata section 的起始地址
OAT_data_end_
OAT_file_end_
boot_image_begin_
boot_image_size_
boot_oat_begin_
boot_oat_size_
image_roots_
仅针对 app image headers 有效
...

▲图21-45　结构图（2/2）

反过来OAT文件也可以访问image中的内容，示意如图21-46所示。

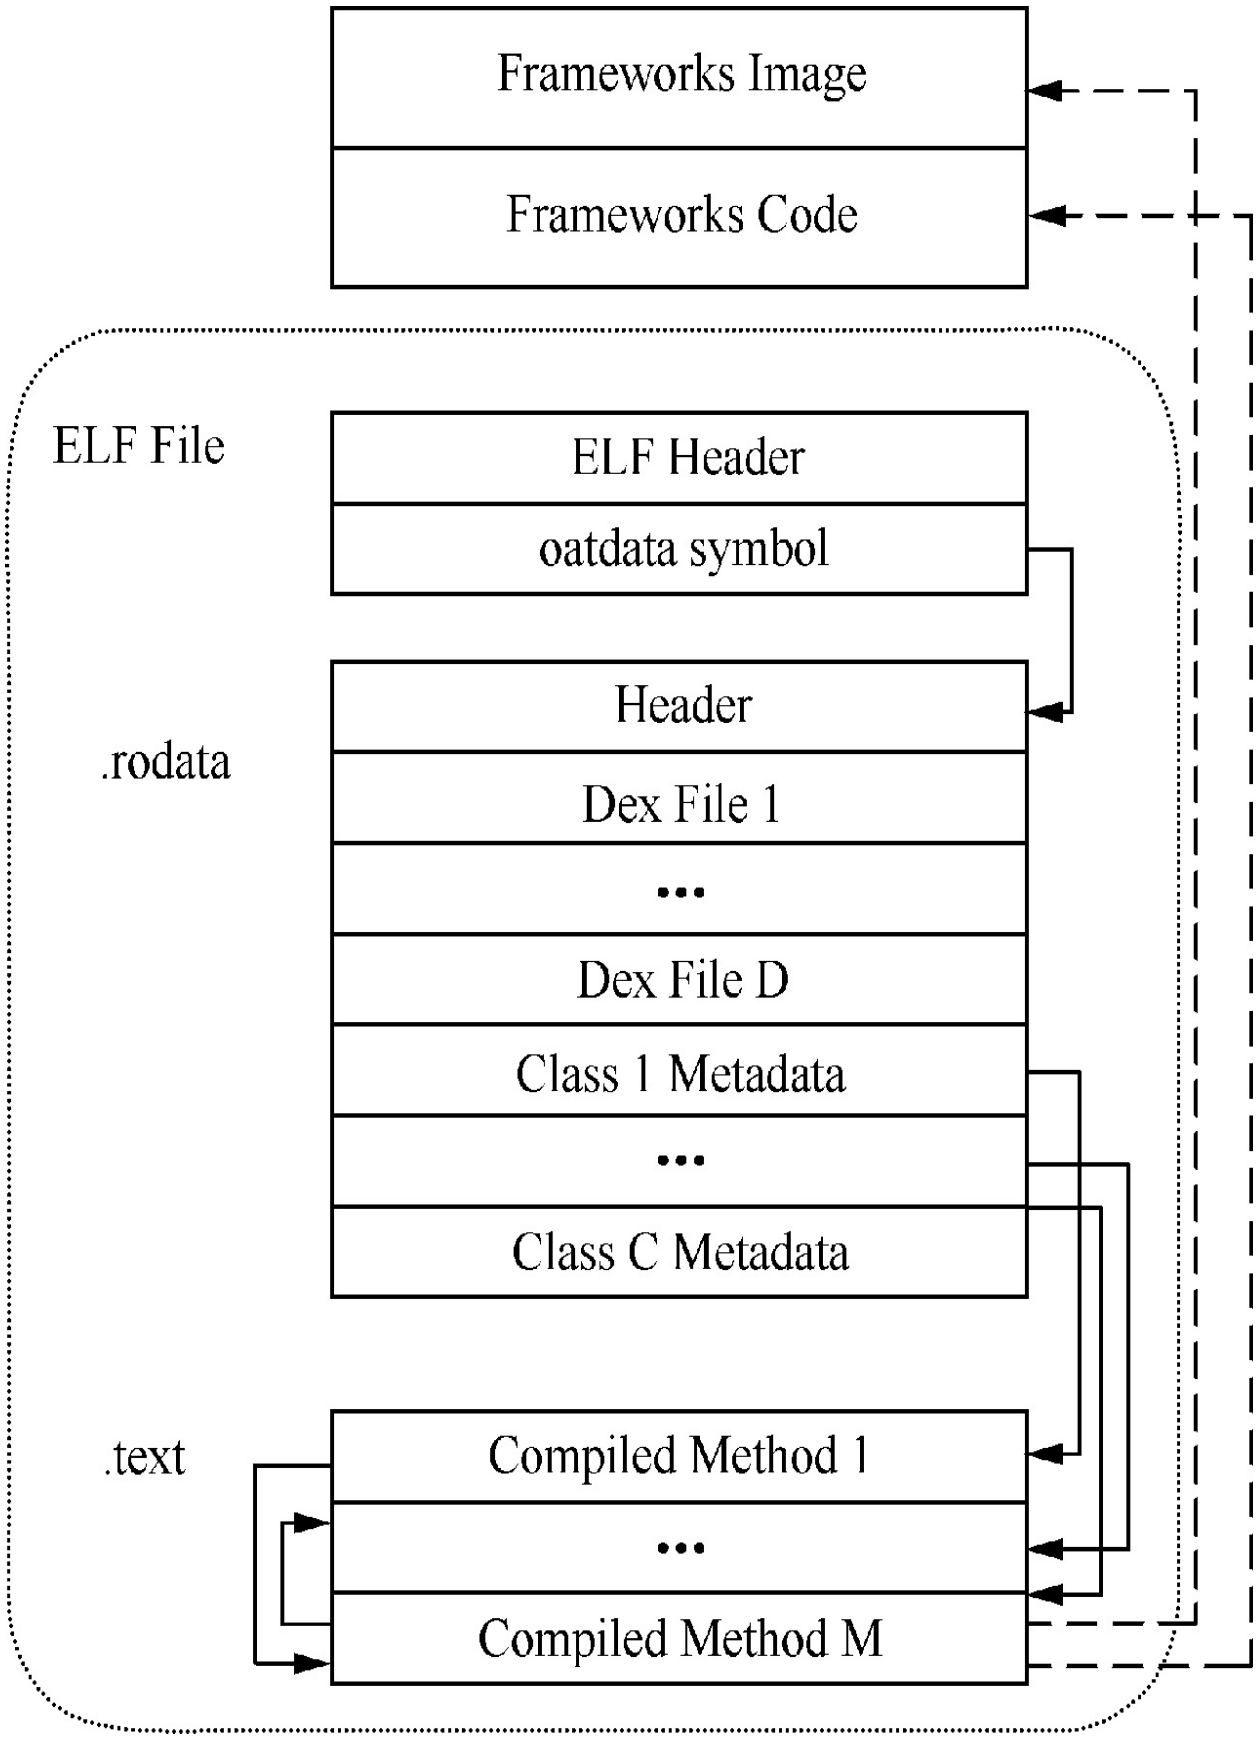
Frameworks Image
Frameworks Code
ELF File
ELF Header
oatdata symbol
.rodata
Header
Dex File 1
...
Dex File D
Class 1 Metadata
...
Class C Metadata
.text
Compiled Method 1
...
Compiled Method M

▲图21-46 Image和OAT之间的引用关系 {-:-}引用自2014年Google I/O大会上的分享

因为Boot.art中包含的Frameworks Image和Frameworks Code可以供OAT中的Compiled Method直接调用和访问，而不需要在程序启动时再去动态创建；而且Framework中包含的很多数据对于大部分Art应用程序都是必需的，访问频度相当高，所以这样的设计无疑可以在很大程度上提升程序的启动和运行时速度。

21.4.2 OAT的两个编译时机

在Android N版本之前（Android N版本中对OAT的编译时机和方式进行了调整，可以参见后续JIT小节的详细分析），dex2oat主要发生在两个阶段：在Android系统构建过程中执行（主要针对预装的应用程序和系统应用程序）；以及第三方应用程序安装过程中执行（只针对第三方应用程序）。主要过程描述如下：

- 系统的预装程序

Android本身预装有各种系统程序和应用程序，这些APK在设备出厂之前就已经确定下来了（通常是各设备厂商在原生Android版本上完成一定程度的定制。例如引入自家的UI实现，增删应用程序等）。更为重要的是，系统编译时其所针对的硬件平台显然是确定的——这是OAT能正常开展编译工作的前提条件之一（OAT是一种扩展的ELF文件，它们所包含的代码指令都是需要针对具体硬件平台来编译产生的）

- 第三方应用程序

我们知道Art虚拟机在运行效率上取胜的“独门秘诀”是AOT，即事先就把Java代码编译成机器指令的一种技术手段。但是这里存在一个问题——对于第三方应用程序（例如微信、QQ等）来说，它们将来会被用户在哪个硬件平台上安装运行是未知的。所以这种情况下没有办法采用和系统预装时一样的作法，即在应用程序的开发构建阶段就把它们编译成OAT文件。

另外，我们还需要考虑第三方应用程序与Android系统版本的兼容性问题。因为终端用户所使用的Android设备的系统版本既可能是6.0（此时Art虚拟机已经完全取代了Dalvik虚拟机），也可能是

4.4（Art和Dalvik虚拟机并存的情况），甚至是2.3（只支持Dalvik虚拟机的情况）——无论哪一个版本，应用程序都应该要能正常工作。综上所述，编译OAT的工作显然无法由第3方应用程序来完成。所以一个比较理想的解决方案是在用户安装第三方应用程序的过程中，通过dex2oat将其编译成OAT文件。

21.4.2.1 Android系统构建过程中的OAT编译

从Android 4.4版本开始，在Android系统构建的最后阶段都会执行dex2oat编译。我们可以首先从编译脚本的角度窥探出这其中的“来龙去脉”：

```
/*build/core/main.mk*/
…
include $(BUILD_SYSTEM)/dex_preopt.mk
```

由于历史原因，dex_preopt.mk脚本中掺杂了很多dex和opt相关的操作，大家注意区分对待。上述语句通过一个统一的dex_preopt.mk来决定如何对dex文件进行“预优化”操作——这其中就包含了我们关心的dex2oat编译：

```
/*build/core/dex_preopt.mk*/
…
include $(BUILD_SYSTEM)/dex_preopt_libart.mk

# Define dexpreopt-one-file based on current default runtime.
# $(1): the input .jar or .apk file
# $(2): the output .odex file
define dexpreopt-one-file
$(call dex2oat-one-file,$(1),$(2))
endef
…
```

上述脚本中有两个地方需要我们特别注意：

- Dalvik和Art虚拟机都有各自的预优化脚本

在Android老版本中，对Dalvik的预优化是有条件的——编译系统会利用一个名为DALVIK_VM_LIB的变量来判断是否需要执行dexopt（DALVIK_VM_LIB等于libdvm.so的时候）；而Art虚拟机下的预编译则是无条件的。

Android N版本已经彻底摈弃了Dalvik虚拟机，所以只留下了Art程序的预优化脚本dex_preopt_libart.mk。

- dexpreopt-one-file函数

函数dexpreopt-one-file用于完成对dex2oat-one-file的调用，后者的定义则在dex_preopt_libart.mk中——简单来讲它为dex2oat程序的执行提供了上下文环境。我们稍后会做进一步分析。

大家先来思考一下，我们应该在编译的哪个阶段执行dex2oat这个预优化操作呢？

至少有两种可选的方案：其一是在Android系统编译的最后一刻针对所有需要预优化的对象做统一处理；另一种方案则是“卡住”需要执行优化操作的所有模块（如.jar,.apk）的“咽喉要道”，然后由它们自行完成任务——Android编译系统采用的是后面这种方式。

这些模块的“咽喉要道”是什么呢？我们知道dex2oat的输入源是Dex程序，那么问题就自然而然转化为——产生Dex的地方都可能成为我们的目标对象。相信读者们已经能想到Android是怎么做的了（注意：是否需要做预优化，以及针对哪些元素展开预优化都是可以配置的。鉴于在前述小节已经对此做过分析，下面的内容中我们直接假设预优化操作是需要的）：

（1）java_library.mk

我们知道，通过编译系统预先提供的诸如BUILD_JAVA_LIBRARY、BUILD_STATIC_JAVA_LIBRARY、BUILD_PACKAGE之类的模板可以方便地完成不同类型模块的编译。其中$（BUILD_JAVA_LIBRARY）用于编译共享的Java库（例如framework.jar、am.jar、services.jar等，它们都会存储到终端设备的/system/framework目录中），它实际上也是利用java_library.mk实现的。这个脚本中与dex2oat相关的部分如下所示：

```
/*build/core/java_library.mk*/
…
$(built_odex) : $(dir $(LOCAL_BUILT_MODULE))% : $(common_javalib.
     @echo "Dexpreopt Jar: $(PRIVATE_MODULE) ($@)"
     $(call dexpreopt-one-file,$<,$@)
```

上述脚本片段中使用的是makefile的静态模式，主要目的在于处理多个Built Odex的情况。函数dexpreopt-one-file我们在前面已经看到过了；它的第1个参数$<表示首个Prerequisite，即$(common_javalib.jar)；另一个参数$@表示目标对象，即通过$(dir $(LOCAL_BUILT_MODULE))%模式来匹配$(built_odex)集合而得到的目标。

现在是时候分析dexpreopt-one-file的内部实现了：

```
/*build/core/dex_preopt_libart.mk*/
# $(1): the input .jar or .apk file
# $(2): the output .odex file
define dex2oat-one-file
$(hide) rm -f $(2)
$(hide) mkdir -p $(dir $(2))
$(hide) $(DEX2OAT) \
     --runtime-arg -Xms$(DEX2OAT_XMS) --runtime-arg -Xmx$(DEX2OAT
     --boot-image=$(PRIVATE_DEX_PREOPT_IMAGE_LOCATION) \
     --dex-file=$(1) \
     --dex-location=$(PRIVATE_DEX_LOCATION) \
     --oat-file=$(2) \
     --android-root=$(PRODUCT_OUT)/system \
     --instruction-set=$($(PRIVATE_2ND_ARCH_VAR_PREFIX)DEX2OAT_TA
     --instruction-set-variant=$($(PRIVATE_2ND_ARCH_VAR_PREFIX)DE
     --instruction-set-features=$($(PRIVATE_2ND_ARCH_VAR_PREFIX)D
     --include-patch-information --runtime-arg -Xnorelocate --no-
     --abort-on-hard-verifier-error \
     $(PRIVATE_DEX_PREOPT_FLAGS)
endef
```

上述函数的实现重心在$(DEX2OATD)这个变量。顾名思义，它的工作就是将Dex（或者Jar）转化为OAT，具体对应的是名为dex2oatd的应用程序。另外，细心的读者可能会发现脚本中其实还有一个与之很类似的变量dex2oat——简单来讲，结尾所含的“D”代表DEBUG，因而它们二者之间的区别就在于是否开启了DEBUG模式。

无论是dex2oat还是dex2oat，在Android系统编译的场景下都属于HOST EXECUTABLE，即运行于开发机器之上的可执行程序。而适用于第3方应用程序的dex2oat则需要运行于终端设备平台上，请大家特别注意这些区别。

dex2oat接受两种类型的输入：.jar或者.apk（内部包含.dex），

由$(1)参数指定；输出的是.odex文件，由$(2)指定。在java_library.mk这个场景中，$(1)具体指的是.jar文件(如framework.jar)，$(2)对应的是$(built_odex)。

dex2oat的源码目录是/art/dex2oat，它的Android.mk中的核心描述语句（非DEBUG，HOST的情况）如下所示：

```
/*art/dex2oat/Android.mk*/
…
ifeq ($(Art_BUILD_HOST_NDEBUG),true)
  $(eval $(call build-art-executable,dex2oat,$(DEX2OAT_SRC_FILES)
endif
```

表面上dex2oat子项目只包含dex2oat.cc一个源文件，但事实上它还依赖于很多其他模块，例如art/compiler、libcutils等。另外，dex2oat是基于LLVM这个通用的编译框架完成的。它的内部实现涉及的技术面很广，并非本小节所需要关心的内容，所以我们暂时不做深入解析，有兴趣的读者可以自行阅读源码了解详情。

（2）Package_internal.mk

和java_library.mk的情况类似，package_internal.mk是为BUILD_PACKAGE服务的，即用于生成APK文件。这个脚本中与dex2oat编译相关的核心语句如下所示：

```
/*build/core/package_internal.mk*/
…
ifdef LOCAL_DEX_PREOPT
$(built_odex): PRIVATE_DEX_FILE := $(built_dex)
# Use pattern rule - we may have multiple built odex files.
$(built_odex) : $(dir $(LOCAL_BUILT_MODULE))% : $(built_dex)
     $(hide) mkdir -p $(dir $@) && rm -f $@
     $(add-dex-to-package)
     $(hide) mv $@ $@.input
     $(call dexpreopt-one-file,$@.input,$@)
     $(hide) rm $@.input
endif
```

在这个场景下，PRIVATE_DEX_FILE是一种Target-Specific Variable，以确保PRIVATE_DEX_FILE只对$(built_dex)这个特定的目标对象有效。这种用法我们在本书编译系统章节中已经做过分析，大家可以结合起来阅读。

PRIVATE_DEX_FILE是add-dex-to-package中所必需的变量；后者是一个define实现，它的主要功能是打包Dex（即built_dex），如下所示：

```
/*build/core/definitions.mk*/
define add-dex-to-package
$(hide) zip -qj $@ $(dir $(PRIVATE_DEX_FILE))classes*.dex
endef
```

经过add-dex-to-package调用后，$@代表的是classes*.dex（可能有多个）形成的zip包——紧接着我们就利用mv命令来将其改名为$@.input。这同时也是dexpreopt-one-file的第一个参数，以及dex2oat程序的“输入源”；另一个参数则是$@，同时也是dex2oat的“输出源”。

这样一来Android工程中的APK通过引用BUILD_PACKAGE这个模板，就可以同时实现dex2oat编译了。

（3）Prebuilt_internal.mk

Prebuilt是对已预先编译好的模块所采取的一种处理手段，对应的模板是BUILT_PREBUILT和BUILD_MULTI_PREBUILT（它们的区别在于模块的数量）。Prebuilt_internal.mk则是Prebuilt的内部实现，其中与dex2oat相关的核心脚本如下所示：

```
/*build/core/prebuilt_internal.mk*/
ifdef LOCAL_DEX_PREOPT
$(built_odex) : $(my_prebuilt_src_file)
     $(call dexpreopt-one-file,$<,$@)
endif
```

Prebuilt本身功能比较简单，在调用dexpreopt-one-file时传入的第1个参数是$<，代表第1个目标依赖对象$(my_prebuilt_src_file)；第2个参数$@代表dex2oat的输出结果。这和前面两种脚本模板中的情况是大同小异的，因而我们不再赘述。

21.4.2.2 dex2oat的用法

dex2oat的内部实现涉及编译原理、LLVM等很多知识点，限于篇幅我们不做深入介绍。但是大家最少应该对dex2oat做到“知其然”，所

以本小节的重点是讲解dex2oat这个工具的用法。

dex2oat根据目标平台的不同分为两个版本，即Host端和Target端。不过它们二者的内部实现是大同小异的，所以接下来的分析以Host端的dex2oat为主。

表21-8所示是dex2oat程序所支持的选项参数。

表21-8　dex2oat的核心选项

Options	Description
-j<number>	指定执行编译操作所需的线程数量
--dex-file=<dex-file>（输入参数）	指定需要被编译的.dex,.jar或者.apk文 范例：--dex-file=/system/framework/
--zip-fd=<file-descriptor>（输入参数）	指定一个zip文件（其中包含了需要 的classes.dex）的文件描述符。范例 fd=5
--zip-location=<zip-location>（输入参数）	为--zip-fd文件指定一个符号名。范 zip-location=/system/app/Calculator.a
--oat-file=<file.oat>（输出参数）	以文件名的形式指定OAT的输出目 例：--oat-file=/system/framework/boo
--oat-fd=<number>（输出参数）	以文件描述符的形式指定OAT的输 标。范例：--oat-fd=6

--oat-location=<oat-name>（输出参数）	为--oat-fd文件指定一个符号名。范例：--oat-location=/data/dalvik-cache/system@app@Calculator.apk.oa
--oat-symbols=<file.oat>（输出参数）	指定带有完全符号表的OAT输出目标例：--oat-symbols=/symbols/system/framework/
--bitcode=<file.bc>	指定bitcode文件名（可选）范例：--bitcode=/system/framework/boot.bc
--image=<file.art>（输出参数）	指定image（输出）目标。范例：--image=/system/framework/boot.art
--image-classes=<classname-file>（输入参数）	指定image中需要包含的classes。范例：--image-classes=frameworks/base/preloa classes
--base=<hex-address>	生成boot image时所采用的基地址。例：--base=0x50000000
--boot-image=<file.art>	指定包含了启动时类路径的Image文例：--boot-image=/system/framework/boot.art
--android-root=<path>	为Portable Linking指定相应的库。范android-root=out/host/linux-x86。如果定的话，默认值是$ANDROID_ROO

--instruction-set=(arm|arm64|mips|x86|x86_64)	指定编译所针对的机器指令集。Exa instruction-set=x8默认值是arm
--instruction-set-features=...	指令集特性。范例：--instruction-set features=div
--compiler-backend=(Quick|Optimizing|Portable)	选定编译器的后端类型（即前面小 的LLVM编译框架的后端）。范例： compiler-backend=Portable默认值是(
--compiler-filter=(verify-none|interpret-only|space|balanced|speed|everything)	指定编译器的过滤选项。范例：--cc filter=everything
--include-debug-symbols --no-include-debug-symbols	分别用于指定需要或者不需要在OA 中包含ELF Symbols
--runtime-arg <argument>	用于指定运行时态的各类参数，譬 堆大小等。范例：--runtime-arg -Xm

总结起来，dex2oat的输入输出关系如图21-47所示。

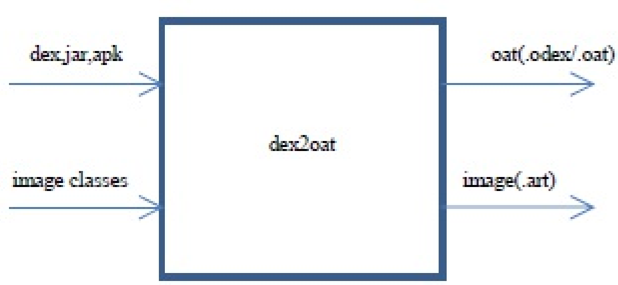

▲图21-47 dex2oat的输入输出关系

其中image文件中包含了一些预初始化过的类，这样可以保证Zygote在加载阶段的速度得到提升（虽然会带来10MB左右的存储空间消耗）。预初始化类的来源主要有两个地方：

（1）frameworks/base/preloaded-classes（可以参见本书的“Android启动过程简析”章节）

（2）--image-classes

值得一提的是，dex2oat的输出结果多数以.odex的后缀名来存储（AndroidM版本）——这一点往往会让开发人员产生误解，将它们和Dalvik中的优化结果相混淆。Android工程提供了不少工具来辅助大家分析OAT和Dex，存储路径是AOSP源码工程下的/out/host/PLATFORM/bin中（比如oatdump、dex2oat等）。下面我们就利用oatdump来分析一个实际的范例/out/target/product/generic/system/app/Calculator/oat/Calculator.odex，输出结果如下：

```
MAGIC:
oat
064

CHECKSUM:
0xe0f6120b

INSTRUCTION SET:
Thumb2

INSTRUCTION SET FEATURES:
smp,-div,-atomic_ldrd_strd
```

oatdump出来的内容很多，包括Calculator这个程序里所有的实现体、体系结构及运行时的地址信息。从上图中的MAGIC NUMBER不难发现，Calculator.odex确实属于“oat”文件。或者我们也可以使用file命令来做进一步观察：

```
s@ubuntu:~/Android_M/out/host/linux-x86/bin$ file Calculator.odex
Calculator.odex: ELF 32-bit LSB  shared object, ARM, EABI5 version 1 (GNU/Linux)
, dynamically linked, stripped
```

file命令的输出结果表示Calculator.odex不仅是一个OAT文件，而且还是一个“ELF Shared Object”。

21.4.2.3 第三方应用程序安装过程中的OAT编译

前面两个小节我们学习了Android系统工程ROM构建阶段生成OAT文件的整个流程。除了系统ROM中内置的Jar包和预装的APK外，还有一个庞大的“Java群体”也需要执行dex2oat编译——即第三方应用程序。

对第三方应用程序执行dex2oat最合适的时机是什么时候？

显然不该由应用程序厂商完成。dex2oat必须是针对具体的硬件平台展开的，而APK在发布之前根本无法精准预测用户手中的硬件设备配置。基于以上原因考虑，由Android系统来完成针对第3方应用程序的dex2oat操作应该就是“情理之中”了。更确切地说，在APK应用程序的安装过程中执行dex2oat就是最佳时机。

接下来我们先从普通用户的角度出发，熟悉一下Android应用程序的安装过程。

用户在通过各种渠道（譬如Google Play、网络搜索、SD卡复制等）获取到自己需要的APK文件后，单击APK文件打开，此时Android系统就会自动启动安装流程了。

那么用户点击打开APK文件时，为什么会自动关联到Android系统的安装服务呢？

这种自动关联的能力实际上是由文件管理器之类的程序通过startActivity实现的。典型范例如下：

```
Uri uri = Uri.fromFile(new File("/mnt/sdcard/TestApk.apk"));
Intent intent = new Intent(Intent.ACTION_VIEW);
intent.setDataAndType(uri,"application/vnd.android.package-archiv
startActivity(intent);
```

Android系统中响应上述Intent的是一个叫做PackageInstallerActivity的Activity，其源码路径是/AOSP/packages/apps/packageinstaller。Package Installer本身也是一个应用程序，在这一点上它和SystemUI等众多系统服务的实现方

式是一致的。

PackageInstallerActivity是带有UI显示界面的，以便可以引导用户来执行安装过程。一旦用户在界面上点选了同意安装协议，那么它就会调用另一个组件InstallAppProgress来进入下一步的工作。

InstallAppProgress一方面会在前台界面显示安装的进度，另一方面还会利用Android系统暴露出来的包管理器接口（PackageManager）来执行具体的安装过程。PackageManager是一个本地代理，其最终对应的系统服务则是PackageManagerService。

大家应该还记得Android中的系统服务会在两个阶段被集中启动：

- init.rc

在这里被启动的多数是本地程序，如vold、installd、ServiceManager等。

- SystemServer.java

在这里被启动的多数为Java层的系统服务，如LightsService、BatteryService等。与应用程序安装相关联的PackageManagerService也是在这里被启动的，核心代码如下所示：

```
// Start the package manager.
Slog.i(TAG, "Package Manager");
mPackageManagerService = PackageManagerService.main(mSyst
  mInstaller, mFactoryTestMode != FactoryTest.FACTORY_TES
```

和其他系统服务一样，PackageManagerService也会在ServiceManager中注册，所取的名称为“package”。这样其他进程通过ServiceManager.getService（“package”）就可以访问它所提供的服务了。不过应用程序通常不需要直接与ServiceManager打交道。Android系统在Context环境（具体的实现在ContextImpl）中提供了getPackageManager来让用户间接使用PackageManagerService提供的服务。另外，getPackageManager得到的对象是PackageManager接口在本地的实现，即ApplicationPackageManager。这个对象为应用程序使用PackageManager提供了进一步的封装。

紧接着安装程序就可以调用PackageMangerService提供的installExistingPackageAsUser或installExistingPackageAsUser接口来进入下一个环节了。其中前者针对的是需要安装的应用程序在系统中已经存在（覆盖安装）的情况，后者则用于处理全新安装时的情况。

到目前为止，应用程序的安装流程如图21-48所示。

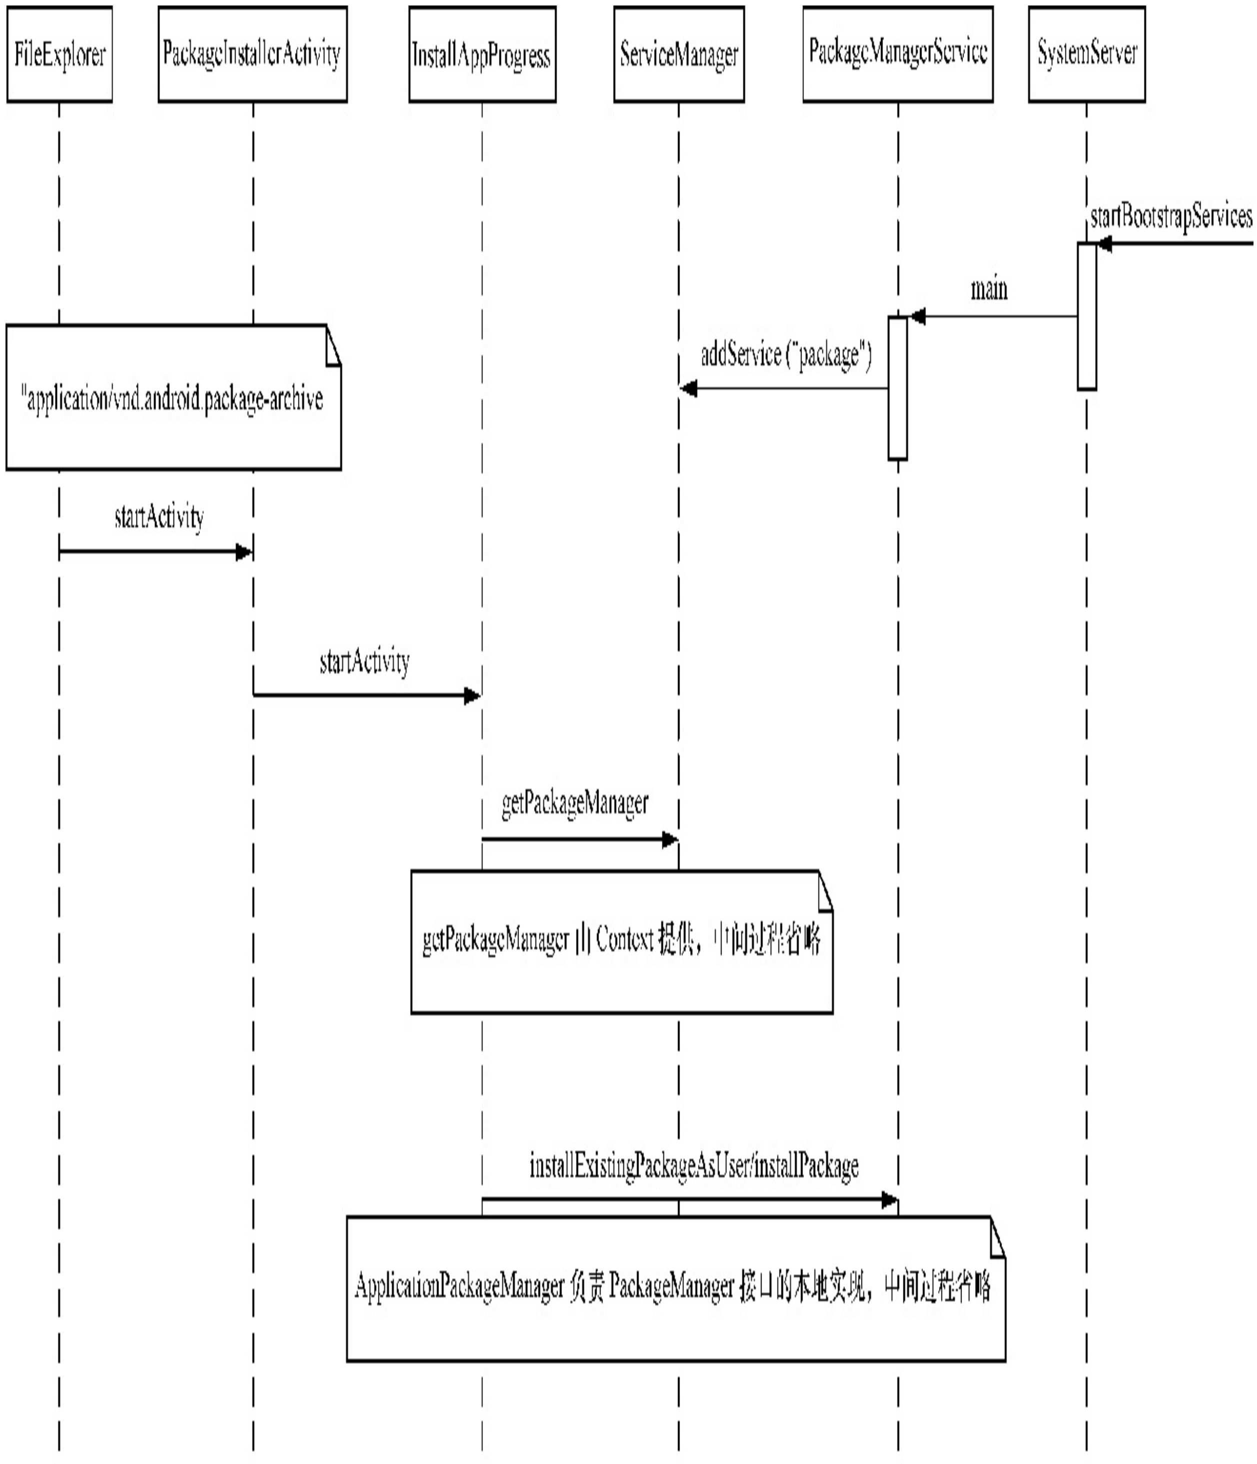

▲图21-48　应用程序的安装流程（1/2）

接下来就该PackageManagerService“粉墨登场”了。

PackageManagerService在安装APK应用程序的过程中，需要与

init.rc中启动的另一个名为installd（Install Daemon）的系统服务进行通信：

```
/*system/core/rootdir/init.rc*/
service installd /system/bin/installd
    class main
    socket installd stream 600 system system
```

这个服务对应的源码路径是:frameworks/native/cmds/installd。

PackageManagerService中持有一个成员变量mInstaller，如下所示：

```
final Installer mInstaller;
```

这个变量是PackageManagerService与installd之间的沟通桥梁。它是SystemServer在构造PackageManagerService时传递给后者的，本质上是一个SystemService的实现体：

```
mInstaller = mSystemServiceManager.startService(Installer.class);
```

SystemServer负责启动上述的Installer服务，后者则在内部通过InstallerConnection与installd建立通信连接。这种连接是基于UNIX Domain Socket完成的，这一点在init.rc启动installd时所用的脚本语句中也可以看出来：

```
socket installd stream 600 system system
```

InstallerConnection连接installd的核心语句如下所示：

```
/*frameworks/base/core/java/com/android/internal/os/InstallerConn
private boolean connect() {
        if (mSocket != null) {//如果已经成功建立连接，那么无需重复操作
            return true;
        }
        Slog.i(TAG, "connecting...");
        try {
            mSocket = new LocalSocket();//Unix Domain Socket

            LocalSocketAddress address = new LocalSocketAddress("
                    LocalSocketAddress.Namespace.RESERVED);

            mSocket.connect(address);//开始连接，直到成功才会返回。如果
```

```
            mIn = mSocket.getInputStream(); //用于从installd读取数据
            mOut = mSocket.getOutputStream(); //用于向installd写入数
        } catch (IOException ex) {
            disconnect();
            return false;
        }
        return true;
    }
```

Connect函数结束后，Installer与installd之间就可以通过mIn和mOut来互相传送数据了。我们以本小节需要解答的，如何对第三方应用程序进行OAT编译的问题为例，看下Installer Connection和installd两者之间的大致交互过程——首先PackageMangerService会判断被安装的APK是否需要进行dex2oat编译。如果答案是肯定的话，它会进一步调用自己的成员变量mInstaller中的dexopt函数：

```
/*frameworks/base/services/core/java/com/android/server/pm/Instal
public int dexopt(String apkPath, int uid, boolean isPublic, Stri
        if (!isValidInstructionSet(instructionSet)) {//指令集是否合
            Slog.e(TAG, "Invalid instruction set: " + instruction
            return -1;
        }

        return mInstaller.dexopt(apkPath, uid, isPublic, instruct
    }
```

大家要注意有两个mInstaller变量，上述dexopt函数中出现的mInstaller指的是Installer Connection对象。它所对应的dexopt实现是：

```
/*frameworks/base/core/java/com/android/internal/os/InstallerConn
    public int dexopt(String apkPath, int uid, boolean isPublic,
            String instructionSet, boolean vmSafeMode) {
        StringBuilder builder = new StringBuilder("dexopt");
        builder.append(' ');
        builder.append(apkPath);
        builder.append(' ');
        builder.append(uid);
        builder.append(isPublic ? " 1" : " 0");
        builder.append(' ');
        builder.append(pkgName);
        builder.append(' ');
        builder.append(instructionSet);
        builder.append(' ');
        builder.append(vmSafeMode ? " 1" : " 0");
```

```
        return execute(builder.toString());
    }
```

StringBuilder负责构造需要向installd传递的命令和详细参数，譬如apkPath、pkgName等。因为installd是一个Linux平台上的可执行程序，所以我们在函数的末尾调用execute来执行它。execute只是做了一个简单的封装，旋即又会调用transact函数，如下所示：

```
/*frameworks/base/core/java/com/android/internal/os/InstallerConn
public synchronized String transact(String cmd) {
       if (!connect()) {//如果目前有可用连接，那么connect会直接返回true
           Slog.e(TAG, "connection failed");
           return "-1";
        }

        if (!writeCommand(cmd)) {//向installd写入带参数的命令
           Slog.e(TAG, "write command failed? reconnect!");
           if (!connect() || !writeCommand(cmd)) {//如果写入失败，可
                                                  //常，此时尝试重新
               return "-1";//仍然失败，返回错误码
           }
        }
        …
        final int replyLength = readReply();//读取installd的执行结果
        if (replyLength > 0) {
            String s = new String(buf, 0, replyLength);
            if (LOCAL_DEBUG) {
                Slog.i(TAG, "recv: '" + s + "'");
            }
            return s;
        } else {
            if (LOCAL_DEBUG) {
                Slog.i(TAG, "fail");
            }
            return "-1";
        }
    }
```

这样一来PMS就成功地把安装命令发送给installd了。

和其他多数系统Daemon程序类似，installd的工作流程也是：启动->等待连接->接收命令->处理命令，如此循环往复。其中installd中处理命令的具体函数是execute：

```
/*frameworks/native/cmds/installd/installd.c*/
```

```
static int execute(int s, char cmd[BUFFER_MAX])
{
    char reply[REPLY_MAX];
    char *arg[TOKEN_MAX+1];
    unsigned i;
    unsigned n = 0;
    unsigned short count;
    int ret = -1;
    reply[0] = 0;

    /* n is number of args (not counting arg[0]) */
    arg[0] = cmd;
    while (*cmd) { //处理所有调用参数，并保存到arg数组(注意：数组最大容量
       if (isspace(*cmd)) {//以空格为分隔符，这点和InstallerConnectic
            *cmd++ = 0;
            n++;
            arg[n] = cmd;
            if (n == TOKEN_MAX) {
                ALOGE("too many arguments\n");
                goto done;
            }
        }
        cmd++;
    }

for (i = 0; i < sizeof(cmds) / sizeof(cmds[0]); i++) {//cmds数组用
                                                     //Handler函
        if (!strcmp(cmds[i].name,arg[0])) {
            if (n != cmds[i].numargs) {//函数参数是否合法
                ALOGE("%s requires %d arguments (%d given)\n",
                     cmds[i].name, cmds[i].numargs, n);
            } else {
                ret = cmds[i].func(arg + 1, reply);//执行Handler
            }
            goto done;
        }
    }
    ALOGE("unsupported command '%s'\n", arg[0]);

done:
    …//处理结果略
    return 0;
}
```

Installd内部维护着一个cmds数组，用于管理command和正确的Handler之间的映射（譬如“dexopt”命令对应的处理函数是do_dexopt）。这种写法在daemon类型的程序中很常见，大家可以留意

一下。不过do_dexopt并没有做很多工作，它会进一步调用dexopt函数。后者的代码实现比较长，我们重点关注与dex2oat编译相关的部分：

```
/*frameworks/native/cmds/installd/commands.c*/
int dexopt(const char *apk_path, uid_t uid, bool is_public,
           const char *pkgname, const char *instruction_set,
           bool vm_safe_mode, bool is_patchoat)
{
    struct utimbuf ut;
    struct stat input_stat, dex_stat;
    char out_path[PKG_PATH_MAX];
    char persist_sys_dalvik_vm_lib[PROPERTY_VALUE_MAX];
    char *end;
    const char *input_file;
    char in_odex_path[PKG_PATH_MAX];
    int res, input_fd=-1, out_fd=-1;

    if (strlen(apk_path) >= (PKG_PATH_MAX - 8)) {
        return -1;
    }

property_get("persist.sys.dalvik.vm.lib.2",persist_sys_dalvik_vm_
             "libart.so");//确认虚拟机类型
…
strcpy(out_path, apk_path);
end = strrchr(out_path, '.');//寻找路径中最后一个“.”
if (end != NULL && !is_patchoat) {
        strcpy(end, ".odex");
        if (stat(out_path, &dex_stat) == 0) {
            return 0;
        }
}
    if (create_cache_path(out_path, apk_path, instruction_set)) {
        return -1;
    }

    if (is_patchoat) {…
    } else {
        input_file = apk_path;
    }

    memset(&input_stat, 0, sizeof(input_stat));
    stat(input_file, &input_stat);

    input_fd = open(input_file, O_RDONLY, 0);//打开输入文件，即APK文
    if (input_fd < 0) {
```

```
        ALOGE("installd cannot open '%s' for input during dexopt\
        return -1;
    }

    unlink(out_path);
    out_fd = open(out_path, O_RDWR | O_CREAT | O_EXCL, 0644);//创
    if (out_fd < 0) {
        ALOGE("installd cannot open '%s' for output during dexopt
        goto fail;
    }
    if (fchmod(out_fd,
               S_IRUSR|S_IWUSR|S_IRGRP |
               (is_public ? S_IROTH : 0)) < 0) {//改变文件权限
        ALOGE("installd cannot chmod '%s' during dexopt\n", out_p
        goto fail;
    }
    if (fchown(out_fd, AID_SYSTEM, uid) < 0) {//改变owner
        ALOGE("installd cannot chown '%s' during dexopt\n", out_p
        goto fail;
    }

    // Create profile file if there is a package name present.
    if (strcmp(pkgname, "*") != 0) {
        create_profile_file(pkgname, uid);
    }

    //开始执行转换工作
    pid_t pid;
    pid = fork();
    if (pid == 0) {//子进程，这是真正执行dex2oat编译的地方
                if (setgid(uid) != 0) {//设置group id
            ALOGE("setgid(%d) failed in installd during dexopt\n"
            exit(64);
        }
        if (setuid(uid) != 0) {//设置user id
            ALOGE("setuid(%d) failed in installd during dexopt\n"
            exit(65);
        }
        …
        if (strncmp(persist_sys_dalvik_vm_lib, "libdvm", 6) == 0)
            run_dexopt(input_fd, out_fd, input_file, out_path);
        } else if (strncmp(persist_sys_dalvik_vm_lib, "libart", 6
            if (is_patchoat) {
                run_patchoat(input_fd, out_fd, input_file, out_pa
            } else {
                run_dex2oat(input_fd, out_fd, input_file, out_pat
                 set, vm_safe_mode);
            }
```

```
        } else {
            exit(69);   /* Unexpected persist.sys.dalvik.vm.lib v
        }
        exit(68);   /* only get here on exec failure */
    } else {//父进程，需要等待子进程任务完成
        res = wait_child(pid);
        if (res == 0) {
            ALOGV("DexInv: --- END '%s' (success) ---\n", input_f
        } else {
            ALOGE("DexInv: --- END '%s' --- status=0x%04x, proces
            goto fail;
        }
    }

    ut.actime = input_stat.st_atime;
    ut.modtime = input_stat.st_mtime;
    utime(out_path, &ut);

    close(out_fd);
    close(input_fd);
    return 0;

fail:
    //出错处理
    return -1;
}
```

上述代码段中，系统属性值“persist.sys.dalvik.vm.lib.2”用于指示当前系统使用的虚拟机类型（如Art或dalvik虚拟机）；两个变量out_path和input_file分别用于表示dexopt的输出结果和输入文件。其中out_path简单来说就是把apk_path的后缀名更改为“.odex”，而input_file则表示APK文件的存储路径。不过out_path的最终值要在调用了create_cache_path之后才能被确认下来。

Out_path路径的样式如下所示：

/data/dalvik-cache/[instruction_set]/[以“@”代替apk_path中的“/”]

随后dexopt尝试打开APK文件，同时根据out_path生成一个odex输出文件。同时我们需要对这两个输入输出文件做多个设置步骤才能保证它们能被正常使用，譬如更改它们的文件权限、文件所有者等。

通过前面几个小节的学习，我们知道OAT编译最终是由dex2oat完成的。后者是一个独立的程序，因而需要为它的运行创建一个新的进程。

紧接着dexopt需要针对当前平台的具体情况来做进一步处理——假设是Dalvik虚拟机的话，执行的是run_dexopt；否则才是调用run_dex2oat：

```
/*frameworks/native/cmds/installd/Commands.c*/
static void run_dex2oat(int zip_fd, int oat_fd, const char* input_
    const char* output_file_name, const char *pkgname, const char
    bool vm_safe_mode)
{
    …
    static const char* DEX2OAT_BIN = "/system/bin/dex2oat";
    …
    sprintf(zip_fd_arg, "--zip-fd=%d", zip_fd);
    sprintf(zip_location_arg, "--zip-location=%s", input_file_nam
    execv(DEX2OAT_BIN, (char* const *)argv);
    ALOGE("execl(%s) failed: %s\n", DEX2OAT_BIN, strerror(errno))
}
```

上述这个函数的大部分篇幅是在处理dex2oat所需的参数，例如“--zip-fd”、“--zip=location”等。这些参数与我们在Android系统构建过程中讲解的dex2oat编译选项是完全一致的，大家如果有疑问的话可以回头复习一下。

可以看到，dex2oat在设备中的存储位置是/system/bin/dex2oat。APK应用程序对应的文件描述符会通过“--zip-fd”选项传递给dex2oat，这是因为APK本身就是一个Zip压缩包。最终execv调用dex2oat，并通过已经包含了各种参数的argv来为转换工作提供各种上下文环境。整个转换工作完成了以后，dexopt这个父进程才能返回，并报告处理结果。

至此，针对第三方应用程序的dex2oat编译就顺利完成了，它需要涉及文件管理器（或者其他启动系统安装流程的程序）、Package Manager Service、installd等多个系统组件。

图21-49是整个处理流程的下半部分，供大家梳理参考。

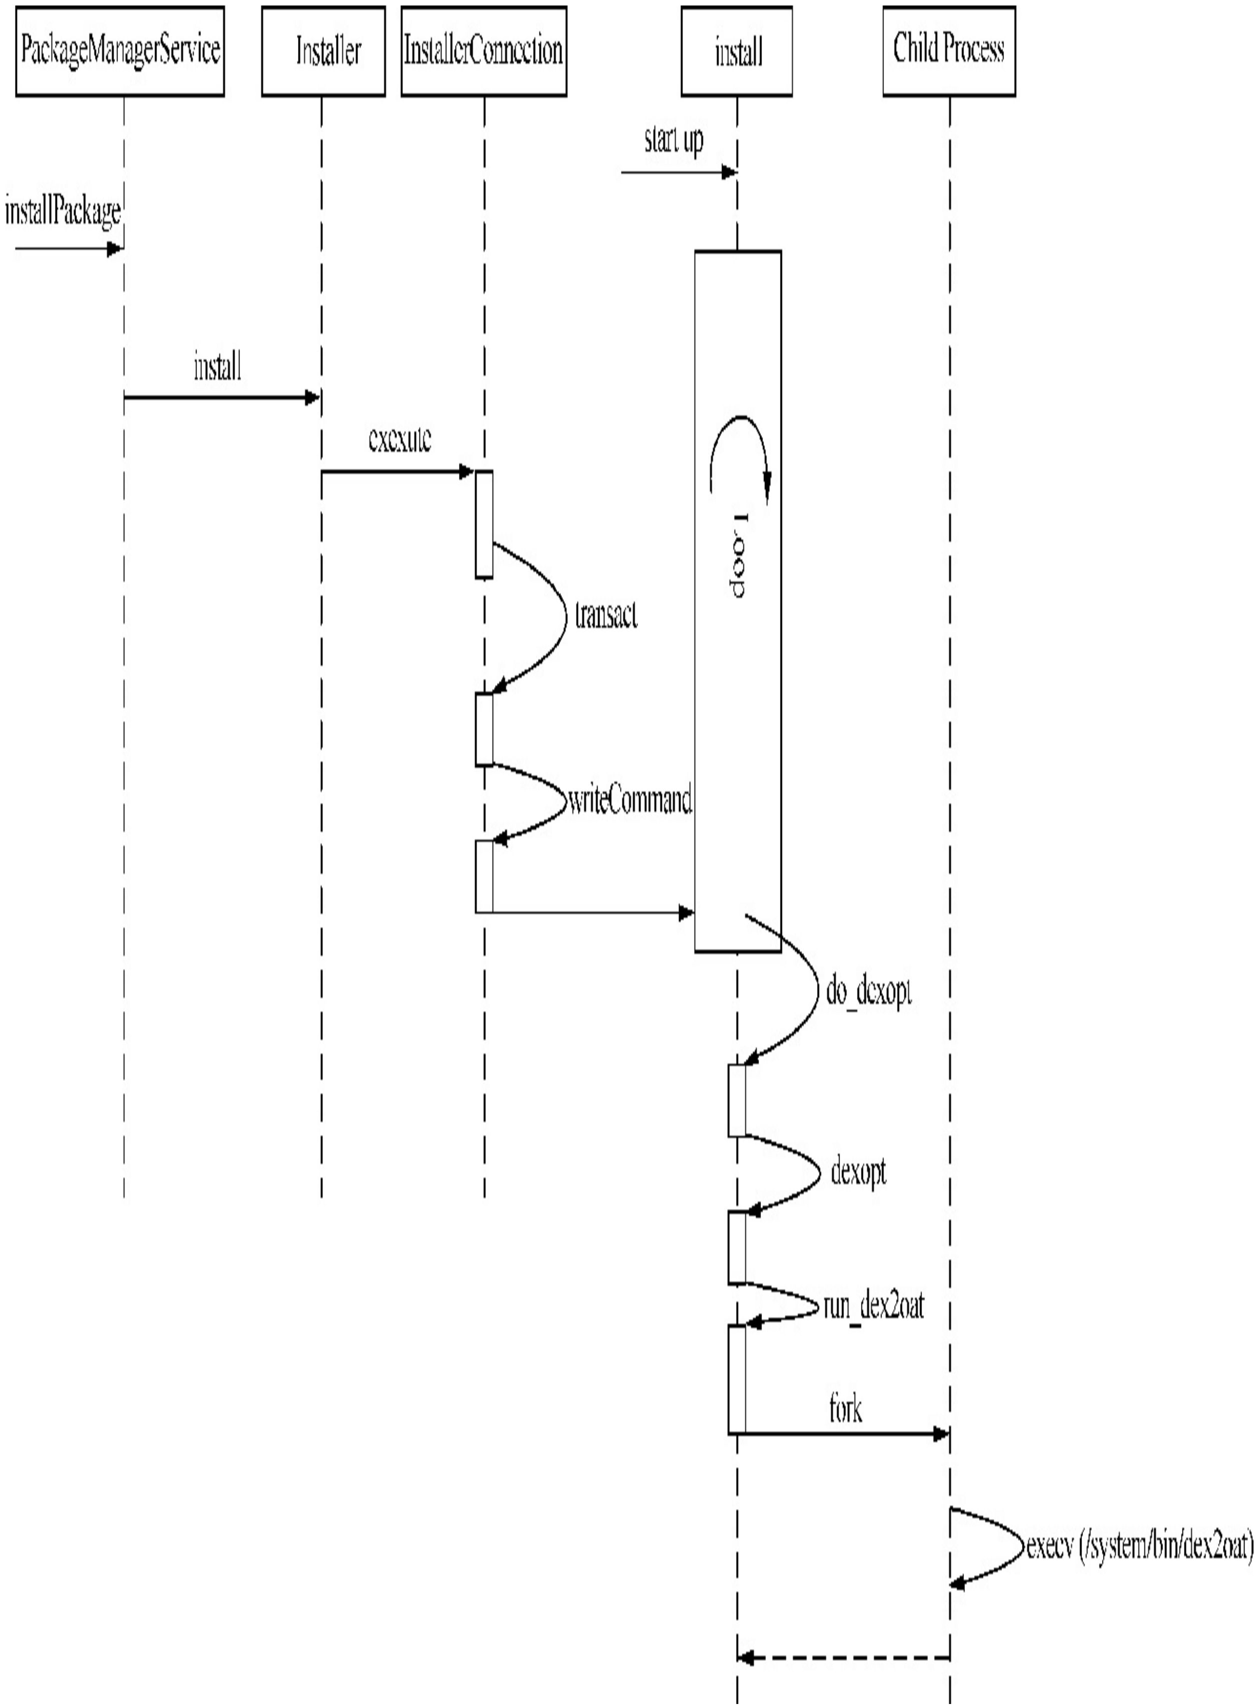
PackageManagerService
Installer
InstallerConnection
install
Child Process
start up
installPackage
install
execute
transact
writeCommand
Loop
do_dexopt
dexopt
run_dex2oat
fork
execv (/system/bin/dex2oat)

▲图21-49　应用程序的安装流程（2/2）

21.5　Android虚拟机的典型启动流程

我们知道每一个应用程序都有自己独立的虚拟机运行时环境,那么具体是由谁来负责启动虚拟机，又是如何启动的呢？

我们首先回顾一下Android系统的开机流程，特别是内核启动完成后系统所做的工作，或许立即就会有答案了，如图21-50所示。

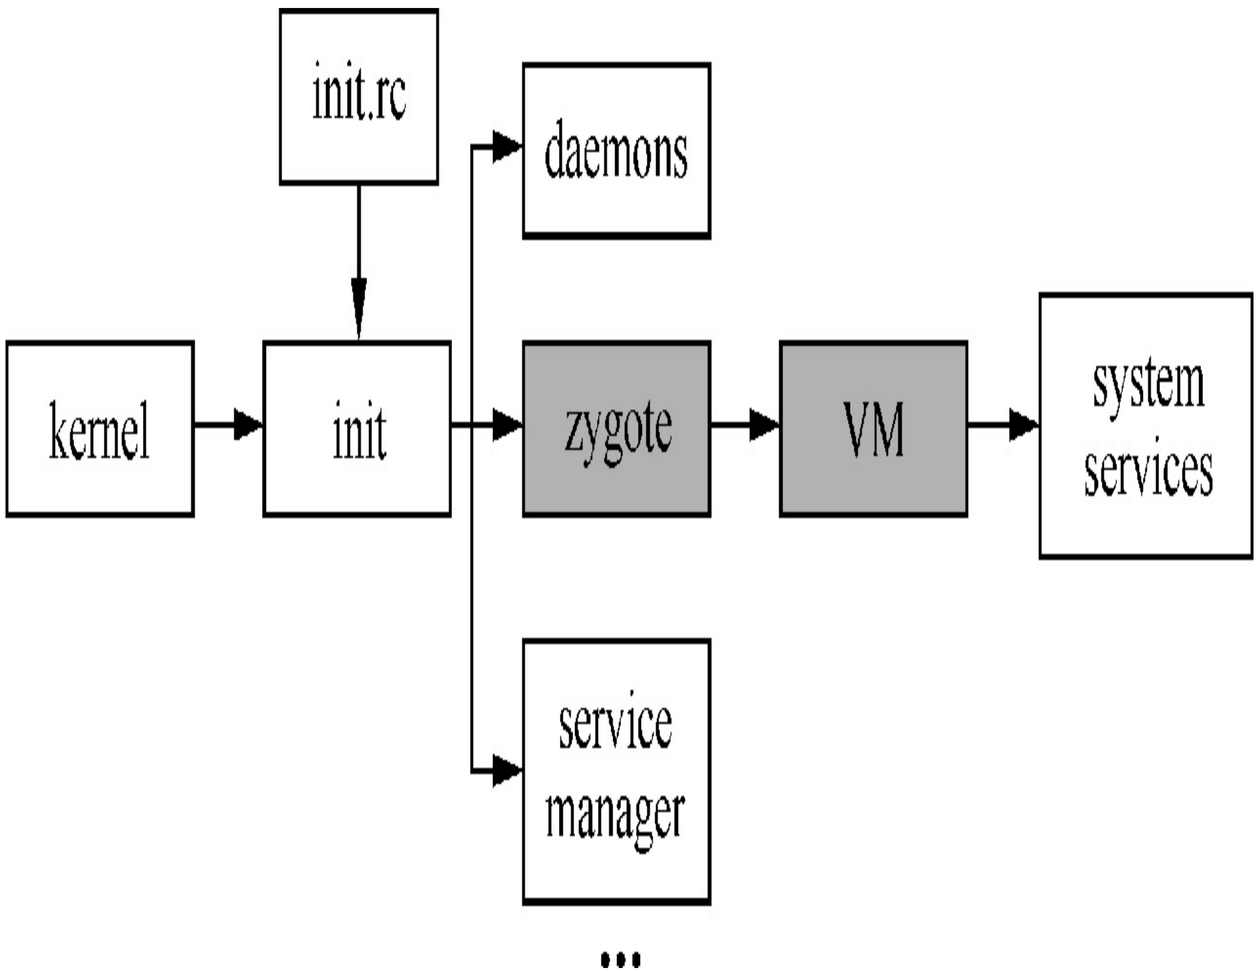

▲图21-50 “系统启动”流程

Android系统中的第一个进程是init，后者又通过解析init.rc脚本来启动关键的守护进程和各种系统服务——其中就包括了zygote这个Android应用程序的“孵化器”。值得一提的是，zygote本身也是由Java语言编写的，所以同样需要虚拟机环境。而系统中后续启动的应用程序多数（注意：这并不是绝对的）是从zygote中fork出来的。

脚本init.rc中与zygote相关的内容如下：

```
service zygote /system/bin/app_process -Xzygote /system/bin --zyg
    class main
    socket zygote stream 660 root system
    onrestart write /sys/android_power/request_state wake
    onrestart write /sys/power/state on
    onrestart restart media
    onrestart restart netd
```

进程app_process是zygote的载体，其源码对应的目录是/frameworks/base/cmds/app_process。当app_process启动后，会调用AndroidRuntime的start函数，如下所示：

```
/*frameworks/base/cmds/app_process/app_main.cpp*/
int main(int argc, char* const argv[])
{
…
    if (zygote) {
        runtime.start("com.android.internal.os.ZygoteInit", args)
    } else if (className) {
        runtime.start("com.android.internal.os.RuntimeInit", args
    } else {
        …
    }
```

由上述代码段可以看到，zygote的入口是“com.android.internal.os.ZygoteInit”；AndroidRuntime::start则负责启动并管理Android虚拟机：

```
/*frameworks/base/core/jni/AndroidRuntime.cpp*/
void AndroidRuntime::start(const char* className, const Vector<St
{…
    /*Step1. 初始化JNI环境*/
    JniInvocation jni_invocation;
    jni_invocation.Init(NULL);//Init函数的参数为library库名，参见后续
    JNIEnv* env;
    if (startVm(&mJavaVM, &env) != 0) {/*Step2. 启动虚拟机，mJavaVM
        return;
    }
    onVmCreated(env);/*Step3. 虚拟机创建成功，执行回调函数通知调用者*/

    if (startReg(env) < 0) {/*Step4. 注册native函数。这些都是预设的jn
        ALOGE("Unable to register all android natives\n");
        return;
```

```
    }

    jclass stringClass;
    jobjectArray strArray;
    jstring classNameStr;

    stringClass = env->FindClass("java/lang/String");
    assert(stringClass != NULL);
    strArray = env->NewObjectArray(options.size() + 1, stringClas
    assert(strArray != NULL);
    classNameStr = env->NewStringUTF(className);
    assert(classNameStr != NULL);
    env->SetObjectArrayElement(strArray, 0, classNameStr);

    for (size_t i = 0; i < options.size(); ++i) {
        jstring optionsStr = env->NewStringUTF(options.itemAt(i).
        assert(optionsStr != NULL);
        env->SetObjectArrayElement(strArray, i + 1, optionsStr);
    }

    /*Step5.开始执行目标对象的主函数
     */
    char* slashClassName = toSlashClassName(className);
    jclass startClass = env->FindClass(slashClassName);
    if (startClass == NULL) {
        ALOGE("JavaVM unable to locate class '%s'\n", slashClassN
        /* keep going */
    } else {
        jmethodID startMeth = env->GetStaticMethodID(startClass,
            "([Ljava/lang/String;)V");
        if (startMeth == NULL) {
            ALOGE("JavaVM unable to find main() in '%s'\n", class
            /* keep going */
        } else {
            env->CallStaticVoidMethod(startClass, startMeth, strA
        }
    }
    …
}
```

上述代码段就是Android中使用和管理虚拟机的典型流程。而且不论是Dalvik或者Art（或者是未来其他可能的新型虚拟机），它们都必须遵循一致的管理方式——这是保证Android虚拟机兼容性的关键所在。

接下来我们将主要针对这5个步骤展开。表面上看似简单的几步，

但其内部实现却异常复杂。所以我们需要花多个小节的阐述才能覆盖它的所有内容，并希望这种“抽丝剥茧”层层深入的方式可以更好地为大家还原出Android虚拟机的内部构造。

Step1@ AndroidRuntime::start。在启动虚拟机之前，需要初始化当前的运行环境。具体是由JniInvocation的Init函数完成的，如下所示：

```
/*libnativehelp/JniInvocation.cpp*/
bool JniInvocation::Init(const char* library) {
  library = GetLibrary(library);//获取虚拟机动态链接库的名称

  handle_ = dlopen(library, RTLD_NOW);//打开虚拟机动态链接库
  …
  /*接下来分别查找VM库中的3个重要接口实现*/
  if (!FindSymbol(reinterpret_cast<void**>(&JNI_GetDefaultJavaVMI
                  "JNI_GetDefaultJavaVMInitArgs")) {
    return false;
  }
  if (!FindSymbol(reinterpret_cast<void**>(&JNI_CreateJavaVM_),
                  "JNI_CreateJavaVM")) {
    return false;
  }
  if (!FindSymbol(reinterpret_cast<void**>(&JNI_GetCreatedJavaVMs
                  "JNI_GetCreatedJavaVMs")) {
    return false;
  }
  return true;
}
```

上述函数首先通过GetLibrary来获得一个动态链接库的名称。或许是历史遗留原因，library变量虽然是作为Init函数入参被传入，但其实际值却是NULL。

GetLibrary中的处理逻辑又细分为如下两种情况：

- 如果系统属性ro.debuggable为0

  表示当前不是可调试版本，此时library直接赋值为libart.so。

- 系统属性ro.debuggable为1

此时将library设置为用户通过persist.sys.dalvik.vm.lib.2设定的值——如果这个属性没有被赋值的话，默认仍然采用libart.so。

在Art和Dalvik并存的时期（如Android 4.4），用户可以在系统菜单中提供的选项来选择希望采用的虚拟机类型。用户的选择同时会被保存成系统属性值，并在上述Init函数中作为虚拟机类型的判断依据（默认值是Dalvik）。当Art虚拟机趋于稳定以后，两种虚拟机并存的关系就被打破了（Android 5.1以上）——系统已经不再支持Dalvik，而改由Art“一枝独秀”。

Art和Dalvik虚拟机动态库之间的关系可以用图21-51来表示。

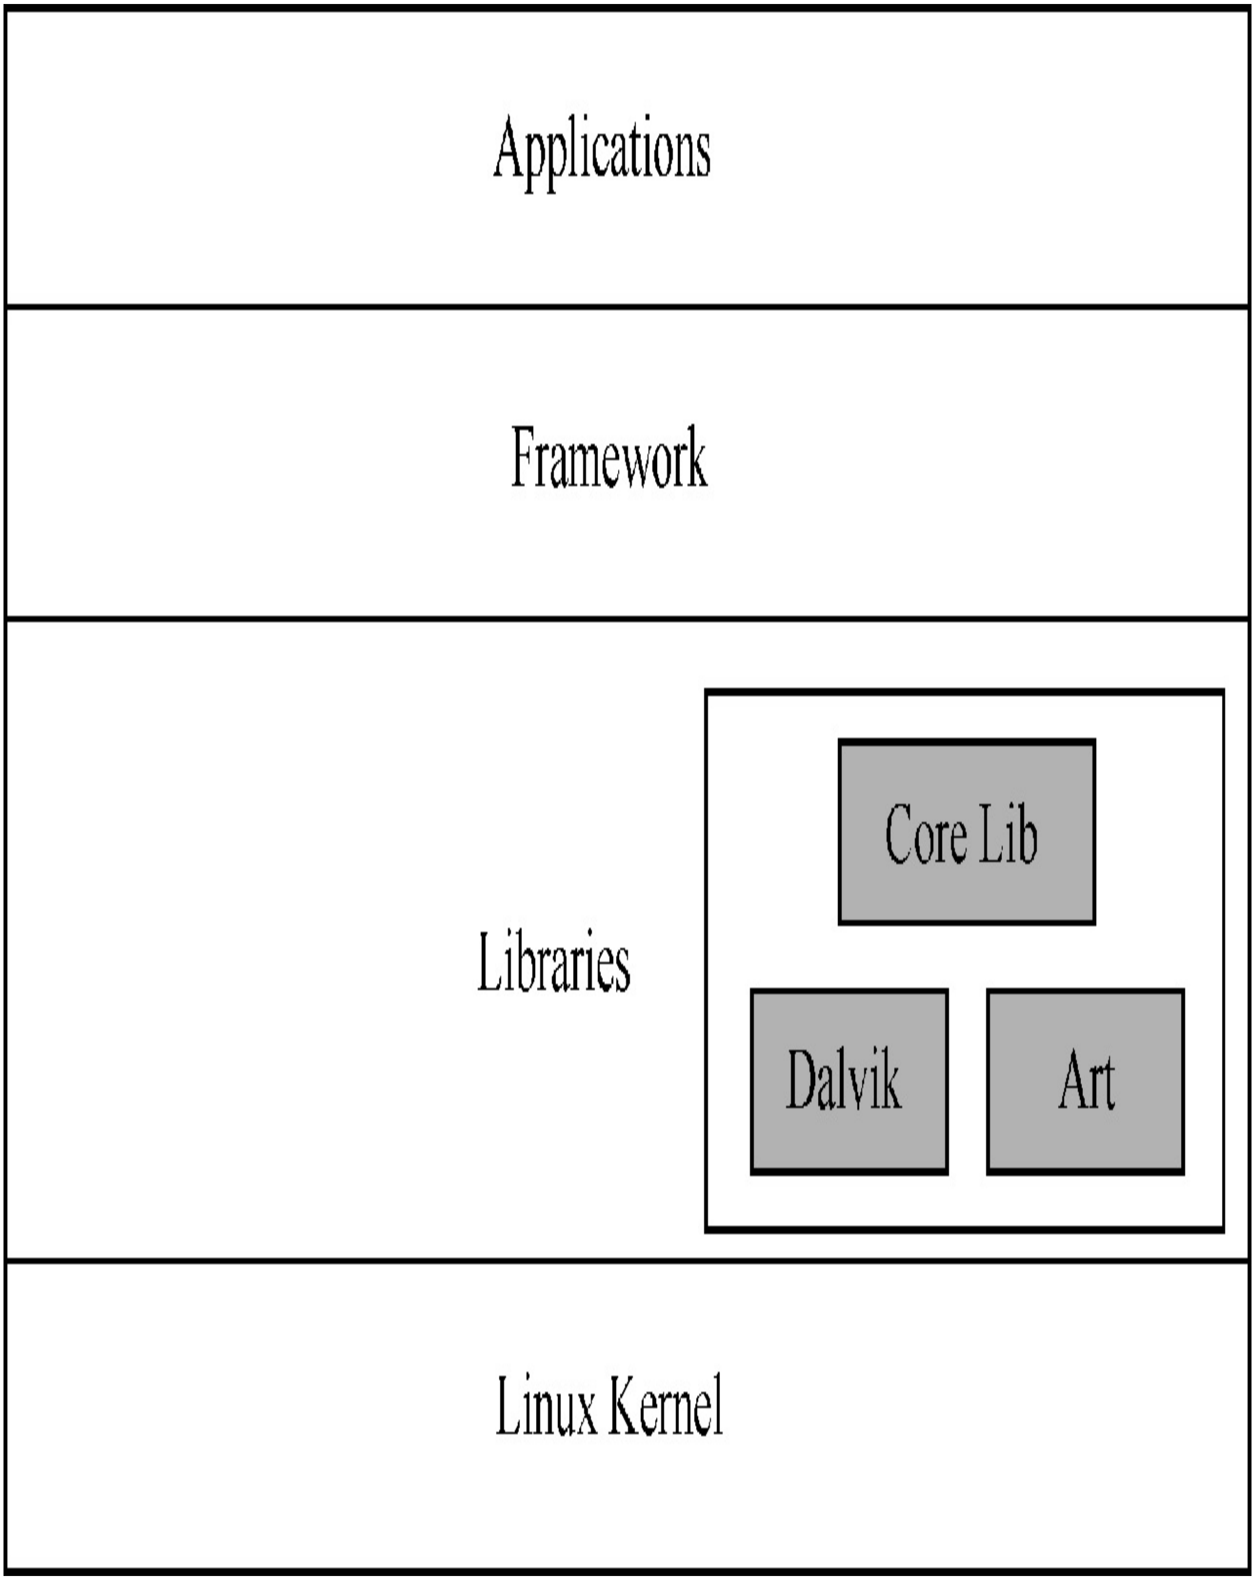

▲图21-51　Dalvik和Art虚拟机库的并存关系

获取到library库的名称后（通常情况下就是“libart.so”），我们需要先通过dlopen（library, RTLD_NOW）把它打开并加载到内存中。C语言为处理动态链接库提供了很多便利的函数，包括dlopen、dlsym、dladdr等，它们统一由bionic/linker提供。其中dlopen用于以指定的模式来打开动态链接库；RTLD_NOW则表示在dlopen()时就直接解析所有未定义的符号。

成功打开虚拟机的动态链接库（如libart.so）以后，我们紧接着需要查找它所包含的3个关键的接口实现，即JNI_GetDefaultJavaVMInitArgs、JNI_CreateJavaVM和JNI_GetCreatedJavaVMs，并分别保存在对应的变量中（需要特别注意一下，这些变量名最后会以下划线结尾，如JNI_CreateJavaVM_）。这几个函数有什么作用呢？——我们可以将它们理解为任何Android虚拟机都必须实现的“门户入口”。换句话说，无论是Art、Dalvik抑或是未来可能的其他Android虚拟机，都必须实现这3个接口，这样才能保证Android系统正确地使用和控制它们。所以如果通过FindSymbol无法找到它们中的任何一个接口函数的话，都将导致失败。

Step2@ AndroidRuntime::start。函数startVM虽然很长，但实际完成的核心工作只有如下两个：

- 初始化虚拟机参数

和Hotspot等JDK标准虚拟机一样，Dalvik/Art同样支持一系列的配置参数，而且它们在很多参数属性上是相似的，譬如“-Xms”“-Xmx”“-XX:BackgroundGC=”等。Android初始化这些参数所采用的默认值通常来源于系统变量，例如下面所示的两条语句：

```
    parseRuntimeOption("dalvik.vm.heapstartsize", heapstartsizeOp
parseRuntimeOption("dalvik.vm.heapsize", heapsizeOptsBuf, "-Xmx",
```

分别指定了堆空间的起始值和最大值。

- 调用JNI_CreateJavaVM

上述步骤中的所有参数值将保存在mOptions@AndroidRuntime中，这是一个JavaVMOption类型的全局变量，然后通过JNI_CreateJavaVM这一标准接口传递给具体的虚拟机实现。

一旦JNI_CreateJavaVM成功返回后，那么就可以认为虚拟机已经处于就绪状态，并可以接受一系列的JNI调用了。

小结：

要点1. Android虚拟机无论是Dalvik或是Art都以动态链接库的形式提供功能，并且需要实现固定的3个接口以保证兼容性。

要点2. 从操作系统的角度来讲，虚拟机程序和普通的进程并没有什么本质区别。

要点3. 虚拟机分为Java和Native两个层面，它们之间需要有效的通信互访机制，即JNI。通常情况下虚拟机的创建者和管理者位于Native中，然后利用JNI来与Java进行访问操作；反之亦然。在startVm这个场景下，JNI_CreateJavaVM成功执行后会得到一个JNIEnv的指针变量，这是后续访问JVM的关键所在。

JNIEnv的定义在jni.h中，它是对JNINativeInterface的typedef，而最终的实现类则是JNIEnvExt。

Step3@ AndroidRuntime::start。经过上面两个步骤的努力，虚拟机已经成功创建（具体过程后续小节有详细分析）完成了，此时我们需要通过回调函数通知用户，即onVmCreated。在app_process这个场景中，用户是指继承于AndroidRuntime的AppRuntime，后者则实现了自己的onVmCreated。具体代码可以参见App_main.cpp文件。

Step4@ AndroidRuntime::start。为虚拟机注册本地函数，代码如下：

```
/*static*/ int AndroidRuntime::startReg(JNIEnv* env)
{
    /*这条语句是保证后续线程的创建都可以被attach到虚拟机上的关键*/
    androidSetCreateThreadFunc((android_create_thread_fn) javaCre

    env->PushLocalFrame(200);

    if (register_jni_procs(gRegJNI, NELEM(gRegJNI), env) < 0) {
        env->PopLocalFrame(NULL);
        return -1;
    }
    env->PopLocalFrame(NULL);
```

```
    return 0;
}
```

PushLocalFrame和PopLocalFrame的作用是管理局部引用的生命周期，它们必须配套出现。所以一旦我们在某个函数中使用了PushLocalFrame，那么在此函数的每一个可能的出口（如return语句）都必须要有相应的Pop操作，否则会引发程序异常。

函数register_jni_procs用于注册一个RegJNIRec列表中包含的所有Native Method，包括下述所示的节选：

```
static const RegJNIRec gRegJNI[] = {
    REG_JNI(register_com_android_internal_os_RuntimeInit),
    REG_JNI(register_android_os_SystemClock),
    REG_JNI(register_android_util_EventLog),
    REG_JNI(register_android_util_Log),
    …
```

以register_android_util_Log为例，它最终调用的是Java虚拟机中的RegisterNativeMethods，并且将实现Log功能所涉及的几个本地函数注册到Java层的“管理者”中，如下所示：

```
static JNINativeMethod gMethods[] = {
    /* name, signature, funcPtr */
    { "isLoggable",      "(Ljava/lang/String;I)Z", (void*) androi
    { "println_native",  "(IILjava/lang/String;Ljava/lang/String;
};
```

我们再对照分析一下Java层提供的Log接口：

```
/*frameworks/base/core/java/android/util/Log.java*/
public static native boolean isLoggable(String tag, int level);
…
public static native int println_native(int bufID,int priority, S
```

通过上面的注册过程，Java层的isLoggable及println_native就与本地层的实现（android_util_Log_isLoggable以及android_util_Log_println_native）“对接”成功了。从JNI的内部实现角度来看，JVM“管理者”所做的工作是将这些本地函数设置为ArtMethod的JNI入口。我们在后续小节中还会有进一步分析。

Step5@ AndroidRuntime::start。“万事俱备，只欠东风”——现在我们要做的就是把任务下发给虚拟机了。大致流程是先利用GetStaticMethodID找到目标类（ZygoteInit）中的main函数，然后再通过CallStaticVoidMethod来执行它，从而开启一个Java程序的“生命之旅”。我们会在后续小节进行详细解析，这里先不赘述。

这样一来典型的Android虚拟机的启动过程就讲解完了。从调用者的角度来看，使用Android平台的虚拟机只有5个核心步骤；从系统内部实现的角度看，隐藏在这5个步骤后的原理却是相当复杂的。所以接下来我们就要深入到它们的内部来为大家呈现一场虚拟机的“内部盛宴”了：

- *启动和初始化虚拟机的内部实现过程*

  即上述的Step1-Step3，将在本小节剩余内容中做详细分析。

- *虚拟机是如何执行Java程序的*

  对应上述Step4-Step5的内部实现，将在后续小节中进行讲解。

其中Step1-Step3的最核心工作又体现在startVm这个函数中，因而我们针对它来做重点分析：

```
/*frameworks/base/core/jni/AndroidRuntime.cpp*/
int AndroidRuntime::startVm(JavaVM** pJavaVM, JNIEnv** pEnv)
{…
    if (JNI_CreateJavaVM(pJavaVM, pEnv, &initArgs) < 0) {
        ALOGE("JNI_CreateJavaVM failed\n");
        goto bail;
}
…
```

前面我们提到过，startVm函数的大部分篇幅都是在处理JavaVMOption对象——从名称不难看出，它是Java虚拟机的配置选项集合，包括“-Xms”“-Xmx”“-XX:BackgroundGC”等。大家不难发现Android虚拟机和标准的Java虚拟机所支持的参数种类和样式都是非常相似的。除了处理配置参数之外，startVm函数会在末尾调用到libart.so或者libdvm.so提供的一个重要接口，即JNI_CreateJavaVM。

在Art虚拟机场景下，JNI_CreateJavaVM函数是由java_vm_ext.cc

文件提供的，具体对应的源码目录是/art/runtime，如下所示：

```
/*art/runtime/java_vm_ext.cc*/
extern "C" jint JNI_CreateJavaVM(JavaVM** p_vm, JNIEnv** p_env, v
  …
  RuntimeOptions options;
  for (int i = 0; i < args->nOptions; ++i) {//解析所有的虚拟机选项
    JavaVMOption* option = &args->options[i];
    options.push_back(std::make_pair(std::string(option->optionSt
                      option->extraInfo));
  }
  bool ignore_unrecognized = args->ignoreUnrecognized;
  if (!Runtime::Create(options, ignore_unrecognized)) {//创建一个Ru
    ATRACE_END();
    return JNI_ERR;
  }
  Runtime* runtime = Runtime::Current();
  bool started = runtime->Start();//通过Runtime来启动其所管理的虚拟机
  if (!started) {//处理启动失败的情况
    …
  }
  *p_env = Thread::Current()->GetJniEnv();
  *p_vm = runtime->GetJavaVM();//获得已经启动完成的虚拟机实例，并通过函
                              //以便后者可以在需要的时候访问和控制虚拟
  ATRACE_END();
  return JNI_OK;
}
```

JNI_CreateJavaVM首先会通过一个Static函数Runtime::Create来创建单实例对象Runtime（希望大家已经能“条件反射”般地联想到这是单实例的典型样式），并调用Runtime::Init来初始化虚拟机——包括Image的加载、垃圾回收器的雏形等。我们可以把Runtime理解为Android虚拟机的“大总管”，它负责提供Davlick/Art的运行时环境。用户提供的所有虚拟机选项也都会交由Runtime处理。

Runtime::Init函数很长，其中最值得我们关心的是它对boot.art和boot.oat的加载过程，如下所示是节选的核心代码：

```
/*art/runtime/runtime.cc*/
bool Runtime::Init(const RuntimeOptions& raw_options, bool ignore
…
  heap_ = new gc::Heap(…);//Step1. 创建堆管理对象
…
  java_vm_ = new JavaVMExt(this, options.get());//Step2. 创建Java
```

```
  Thread::Startup();
  Thread* self = Thread::Attach("main", false, nullptr, false);//
  …
  class_linker_ = new ClassLinker(intern_table_); //Step4. 新建Cla
  //Step5. 初始化Class Linker
  if (GetHeap()->HasBootImageSpace()) {//当前Heap中是否包含Boot Imag
    std::string error_msg;
    bool result = class_linker_->InitFromBootImage(&error_msg);
    …
  } else {
    std::vector<std::string> dex_filenames;
    Split(boot_class_path_string_, ':', &dex_filenames);

    std::vector<std::string> dex_locations;
    if (!runtime_options.Exists(Opt::BootClassPathLocations)) {
      dex_locations = dex_filenames;
    } else {
      dex_locations = runtime_options.GetOrDefault(Opt::BootClass
      CHECK_EQ(dex_filenames.size(), dex_locations.size());
    }

    std::vector<std::unique_ptr<const DexFile>> boot_class_path;
    if (runtime_options.Exists(Opt::BootClassPathDexList)) {
      boot_class_path.swap(*runtime_options.GetOrDefault
                                 (Opt::BootClassPathDexList
    } else {
      OpenDexFiles(dex_filenames,
                   dex_locations,
                   runtime_options.GetOrDefault(Opt::Image),
                   &boot_class_path);
    }
    instruction_set_ = runtime_options.GetOrDefault(Opt::ImageIns
    std::string error_msg;
    if (!class_linker_->InitWithoutImage(std::move(boot_class_pat
      LOG(ERROR) << "Could not initialize without image: " << err
      return false;
    }
…
```

Step1@Runtime::Init.创建Heap对象，这是虚拟机管理堆内存的起点。我们将在后续小节中做专门介绍。

Step2@Runtime::Init.创建一个JavaVMExt对象。需要特别留意的是gJniInvokeInterface，这里存储的是JNI的预置函数，后续我们还会有专门介绍。

Step3@Runtime::Init.在创建ClassLinker之前，需要先Attach主线程。那么这里的“Attach”应该怎么理解呢？我们可以从源码的角度来回答这个问题：

```
/*art/runtime/Thread.cc*/
Thread* Thread::Attach(const char* thread_name, bool as_daemon, j
                       bool create_peer) {
  Thread* self;
  Runtime* runtime = Runtime::Current();//注意：Runtime是进程单实例
  …
  {
    MutexLock mu(nullptr, *Locks::runtime_shutdown_lock_);
    if (runtime->IsShuttingDownLocked()) {
      /*如果Runtime已经处于关闭状态，那么将拒绝新线程的Attach*/
      LOG(ERROR) << "Thread attaching while runtime is shutting d
      return nullptr;
    } else {
      Runtime::Current()->StartThreadBirth();
      /*StartThreadBirth和EndThreadBirth必须配套使用。它们分别会对一个
      threads_being_born_执行加1和减1的操作。换句话说，如果threads_bein
      那么就表示当前有一个Thread正在初始化*/
      self = new Thread(as_daemon);//新建一个线程类
      self->Init(runtime->GetThreadList(), runtime->GetJavaVM());
      Runtime::Current()->EndThreadBirth();//初始化结束
    }
  }

  CHECK_NE(self->GetState(), kRunnable);
  self->SetState(kNative);//设置当前状态为kNative,即运行在Native环境中
  …
  return self;
}
```

从这个Attach函数中我们可以窥伺出Android虚拟机线程管理机制的一点端倪。Dalvik/Art和Java标准虚拟机一样都支持多线程，管理这些线程的重任就落在了Runtime的身上。每一个刚“出生”的线程，都首先需要通过Init函数注册到Runtime内部的线程列表中，如下所示：

```
void Thread::Init(ThreadList* thread_list, JavaVMExt* java_vm) {…
  tlsPtr_.jni_env = new JNIEnvExt(this, java_vm);
  thread_list->Register(this);
}
```

虚拟机中的每个线程都有自己独立的JNI环境，所以上述代码段中会为新线程分配一个自己的JNIEnvExt，紧接着再将自己注册到

thread_list管理列表中。

我们知道，Android虚拟机既要能执行Java代码，也必须能处理Native层的实现，而且这两种情况是需要区分对待的。以Thread::Attach为例，它当前处于Native环境中，因而线程状态会被置为kNative。Art虚拟中的线程还有很多其他状态，如下所示（大家可以参考每个状态后面的注释了解它们的含义，我们就不赘述了）：

```
enum ThreadState {
  //                          Thread.State   JDWP state
  kTerminated = 66,  // TERMINATED TS_ZOMBIE Thread.run has retur
  kRunnable,                  // RUNNABLE       TS_RUNNING   runn
  kTimedWaiting,              // TIMED_WAITING  TS_WAIT      in O
  kSleeping,                  // TIMED_WAITING  TS_SLEEPING  in T
  kBlocked,                   // BLOCKED        TS_MONITOR   bloc
  kWaiting,                   // WAITING        TS_WAIT      in O
  kWaitingForGcToComplete,    // WAITING        TS_WAIT      bloc
  kWaitingForCheckPointsToRun,  // WAITING        TS_WAIT      GC
to run
  kWaitingPerformingGc,       // WAITING        TS_WAIT      perf
  kWaitingForDebuggerSend,    // WAITING        TS_WAIT      bloc
events to be sent
  kWaitingForDebuggerToAttach, // WAITING       TS_WAIT      bloc
debugger to attach
  kWaitingInMainDebuggerLoop,  // WAITING       TS_WAIT      bloc
processing debugger events
  kWaitingForDebuggerSuspension,   // WAITING   TS_WAIT      wait
suspend all
  kWaitingForJniOnLoad,            // WAITING   TS_WAIT      wait
of dlopen and JNI on load code
  kWaitingForSignalCatcherOutput,  // WAITING   TS_WAIT      wait
catcher IO to complete
  kWaitingInMainSignalCatcherLoop, // WAITING   TS_WAIT      bloc
processing signals
  kWaitingForDeoptimization,       // WAITING   TS_WAIT      wait
suspend all
  kWaitingForMethodTracingStart,   // WAITING   TS_WAIT      wait
to start
  kStarting,                       // NEW       TS_WAIT      nati
yet ready to run managed code
  kNative,                         // RUNNABLE  TS_RUNNING   runn
  kSuspended,                      // RUNNABLE  TS_RUNNING   susp
debugger
};
```

Step4@Runtime::Init.成功将主线程Attach到Runtime环境中以后，现在可以创建Class Linker了。简单来说，这个“类链接器”的职责是管理Java Class以及Class内部的所有对象。

Step5@Runtime::Init. 初始化Class Linker。根据当前环境中是否存在Image Space可以细分为如下两种情况：

情况1. Heap中包含了Boot Image Space的情况

大家应该能猜想到这里的Image默认指的是boot.art（注意：不排除用户自己提供一个定制的Image的可能性）。此时Class Linker可以直接调用InitFromBootImage来从Image文件中提取出Boot Class Path，并保存到boot_class_path_中。

GetHeap()函数获取的是前面Runtime::Init中创建的gc::Heap类型的heap_成员变量，即内存堆管理器。而GetHeap()->HasImageSpace()则用于判断当前堆对象中是否含有Image空间。怎么理解Image Space呢？

先来看一下函数HasBootImageSpace，它的实现如下所示：

```
bool HasBootImageSpace() const {
  return !boot_image_spaces_.empty();
}
```

其中boot_image_spaces_是一个std::vector<space::ImageSpace*>类型的变量，这说明ImageSpace的数量理论上可以不止一个（虽然当前版本中实际还是只有一个ImageSpace）。

ImageSpace继承自MemMapSpace，后者又继承自ContinuousSpace，表明它是一个连续的空间；另外系统中还有很多不连续的空间，它们会继承自DiscontinuousSpace，如图21-52所示。

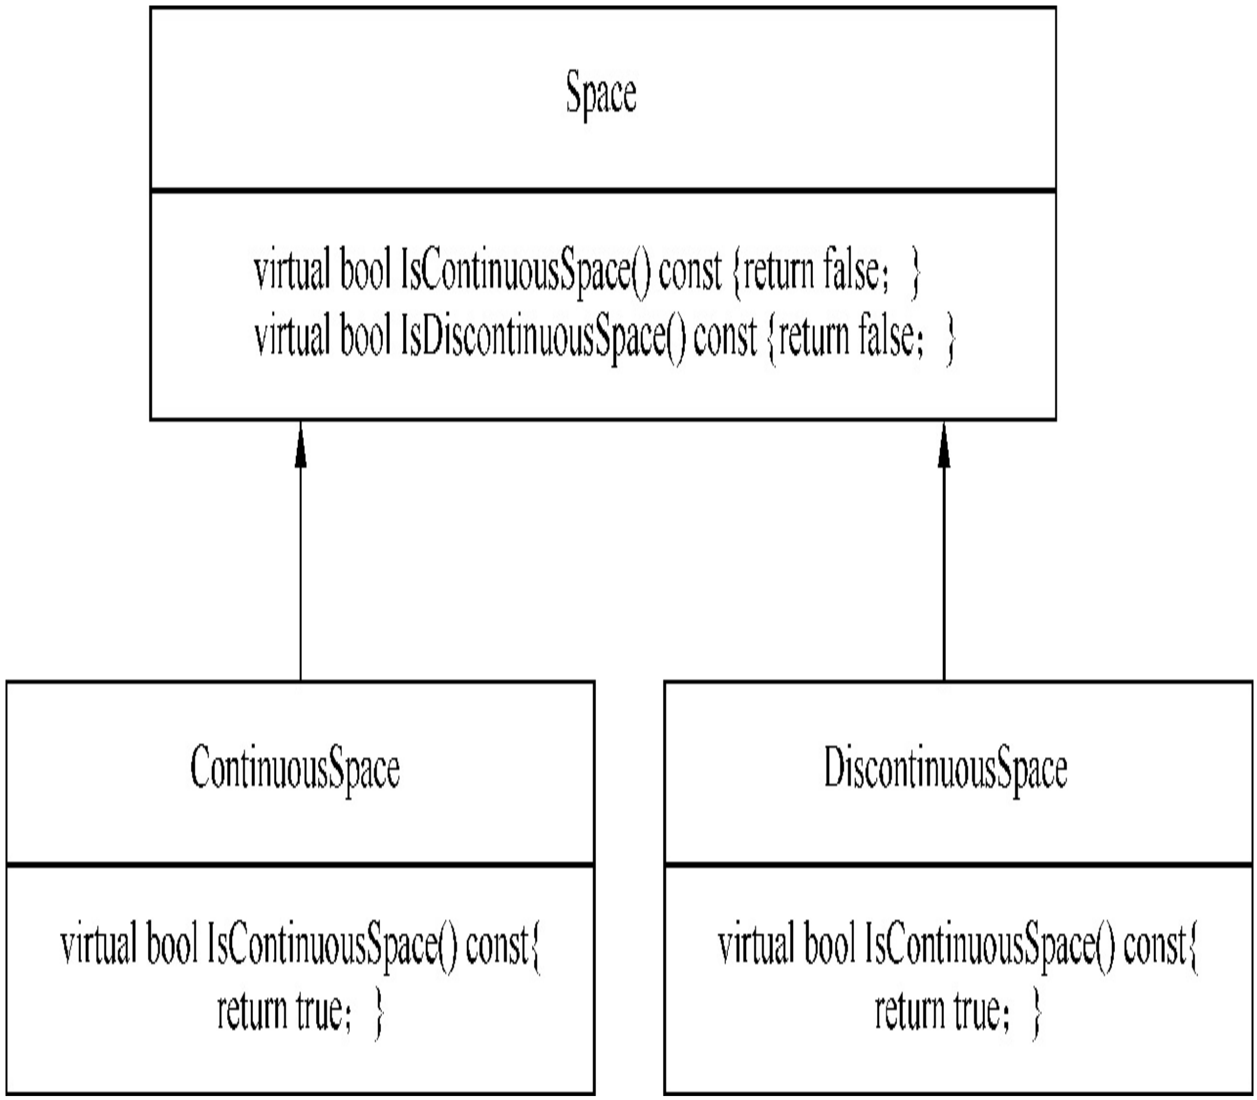

▲图21-52　连续和不连续空间的继承关系

换句话说，继承自ContinuousSpace的对象为连续空间；反之继承自DiscontinuousSpace的对象则为不连续空间。依此判断逻辑，结合代码分析我们可以得出属于连续空间的对象有：ImageSpace、ZygoteSpace等。

ImageSpace是在Heap构造过程中同步生成的，对应语句如下：

```
space::ImageSpace* boot_image_space = space::ImageSpace::Cr
    image_name.c_str(),
    image_instruction_set,
    index > 0,
    &error_msg);
```

其中image_name的赋值分为两种情况，其一是使用Android虚拟机调用者（例如AndroidRuntime）主动通过“-Ximage”参数指定的一个Image；如果调用者没有这么做，并且当前compiler_callbacks_为null的话，那么程序将把它默认赋值为：

GetAndroidRoot()+ "/framework/boot.art"，即/system/framework/boot.art

我们在前面小节说过，系统会在必要的时候（Android M版本中是在应用程序的安装过程中）通过dex2oat把APK中的Dex编译为本地的机器码。在这一操作过程中，dex2oat事实上也会启动一个虚拟机，所以这里的compiler_callbacks_即是这种编译器场景下的“回调函数”。

因为Android中的虚拟机是以动态库的形式（如libart.so）存在的，并对外提供JNI_GetDefaultJavaVMInitArgs、JNI_CreateJavaVM和JNI_GetCreatedJavaVMs三个公共的接口。所以它并不会特别关心调用者是zygote或是dex2oat抑或是其他对象。

关于Image Space及其他Space的更多分析，可以参见后面的Heap小节。

情况2. 当前Heap中没有包含Image的情况

通常这种情况会发生在dex2oat（因为dex2oat也会启动一个虚拟机，并通过指定“compilercallbacks”来获取回调）进程中，此时需要调用InitWithoutImage来确定Boot Class Path。InitWithoutImage的入参boot_class_path实际上是一个DexFile的Vector对象，其中的所有元素都会被AppendToBootClassPath添加到boot_class_path_中。

对于情况1，系统只需要直接加载image就可以了；而另一种情况下虚拟机系统就只能通过手工来主动创建和加载Dex文件了。

至此VM的创建和初始化就基本上完成了。接下来jni_internal中的的JNI_CreateJavaVM会通过调用Start函数来启动已经成功创建的虚拟机对象，其中涉及改变当前线程的运行状态、创建ClassLoader等各个环节。

下面我们给出虚拟机在创建和初始化阶段的流程图，如图21-53所

示。

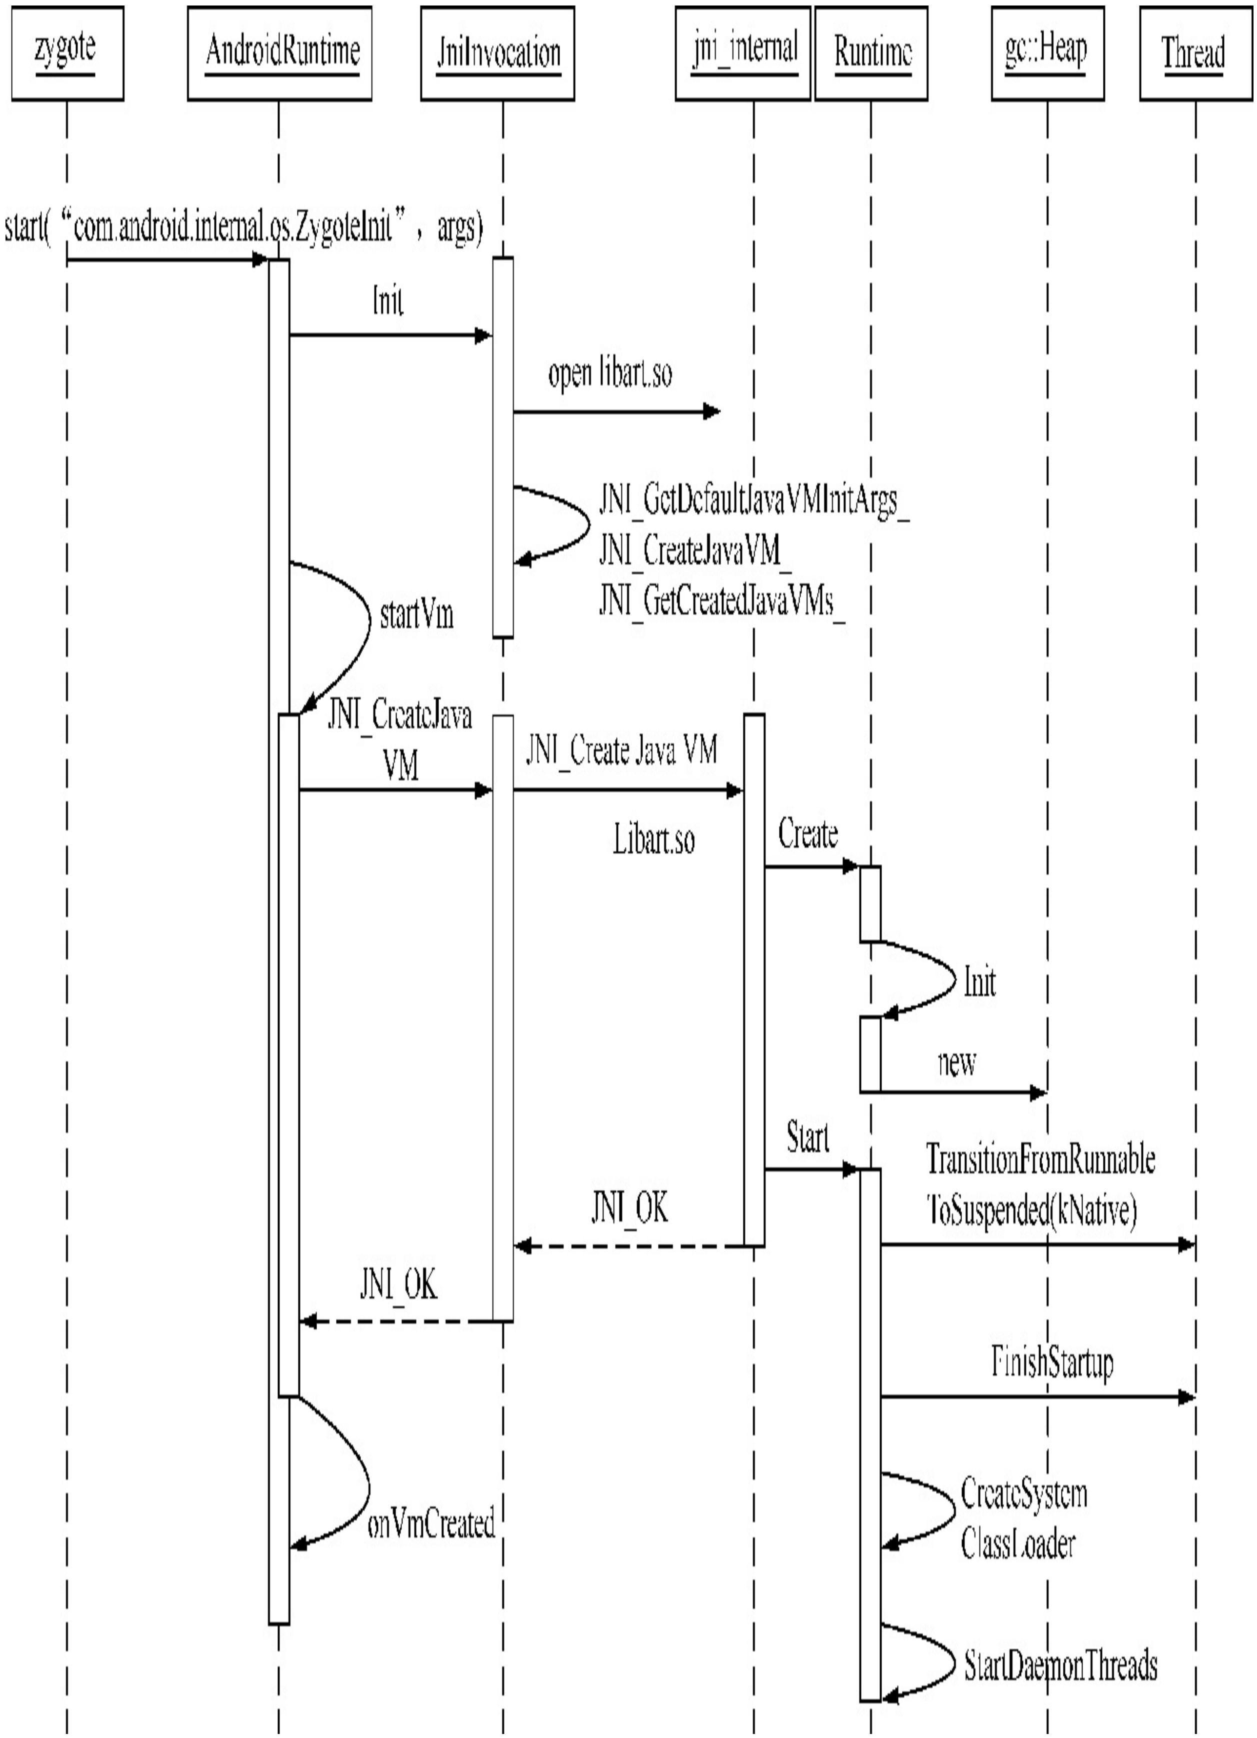
zygote
AndroidRuntime
JniInvocation
jni_internal
Runtime
gc::Heap
Thread
start("com.android.internal.os.ZygoteInit" , args)
Init
open libart.so
JNI_GetDefaultJavaVMInitArgs_
JNI_CreateJavaVM_
JNI_GetCreatedJavaVMs_
startVm
JNI_CreateJava
VM
JNI_Create Java VM
Libart.so
Create
Init
new
Start
TransitionFromRunnable
ToSuspended(kNative)
JNI_OK
JNI_OK
FinishStartup
CreateSystem
ClassLoader
onVmCreated
StartDaemonThreads

▲图21-53　VM的创建和启动流程

21.6 堆管理器和堆空间释义

从前面小节的学习中，我们知道Heap堆管理器将在Runtime::Init中完成构建和初始化。

Android虚拟机中的堆空间有多种不同类型，它们在Heap类中都有对应的成员变量，如表21-9所示。

表21-9 堆空间类型及释义

Member	Description
std::vector<space::ContinuousSpace*> continuous_spaces_;	所有的连续空间集合，对象将被保存在一个连续的内存范围内
std::vector<space::DiscontinuousSpace*> discontinuous_spaces_;	所有的不连续空间集合，对象可能会被分散存储
std::vector<space::AllocSpace*> alloc_spaces_;	可用于内存分配（包括已经分配出去）的所有空间集合
space::MallocSpace* non_moving_space_;	不能被移动的对象记录在这里，这和Art中采用的Compact内存回收算法有关联
	Art中的堆内存分配器（allocator）有多种类

space::RosAllocSpace* rosalloc_space_;	型，这个空间是专门为kAllocatorTypeRosAlloc分配器服务的
space::DlMallocSpace* dlmalloc_space_;	同上，这个空间是专门为kAllocatorTypeDlMalloc分配器服务的
space::MallocSpace* main_space_;	GC用于保存和复制进程状态更新的空间，通常情况下就是上面两个空间之一的代名词
space::LargeObjectSpace* large_object_space_;	这个空间简单来说用于大体积对象的存储

为什么我们需要这么多的Space变量，它们之间又有什么关联呢？

首先，需要强调的是，这些空间并非完全独立的。更确切地讲，上述变量所描述的部分空间区域是存在重叠的。例如continuous_spaces_是一个vector变量，它表示Heap中所有连续空间的集合；而main_space_本身也属于连续空间，它们是对同一空间的不同维度的描述。

从继承关系上来看，这些XXSpace之间可以说是“息息相关”的，如图21-54所示。

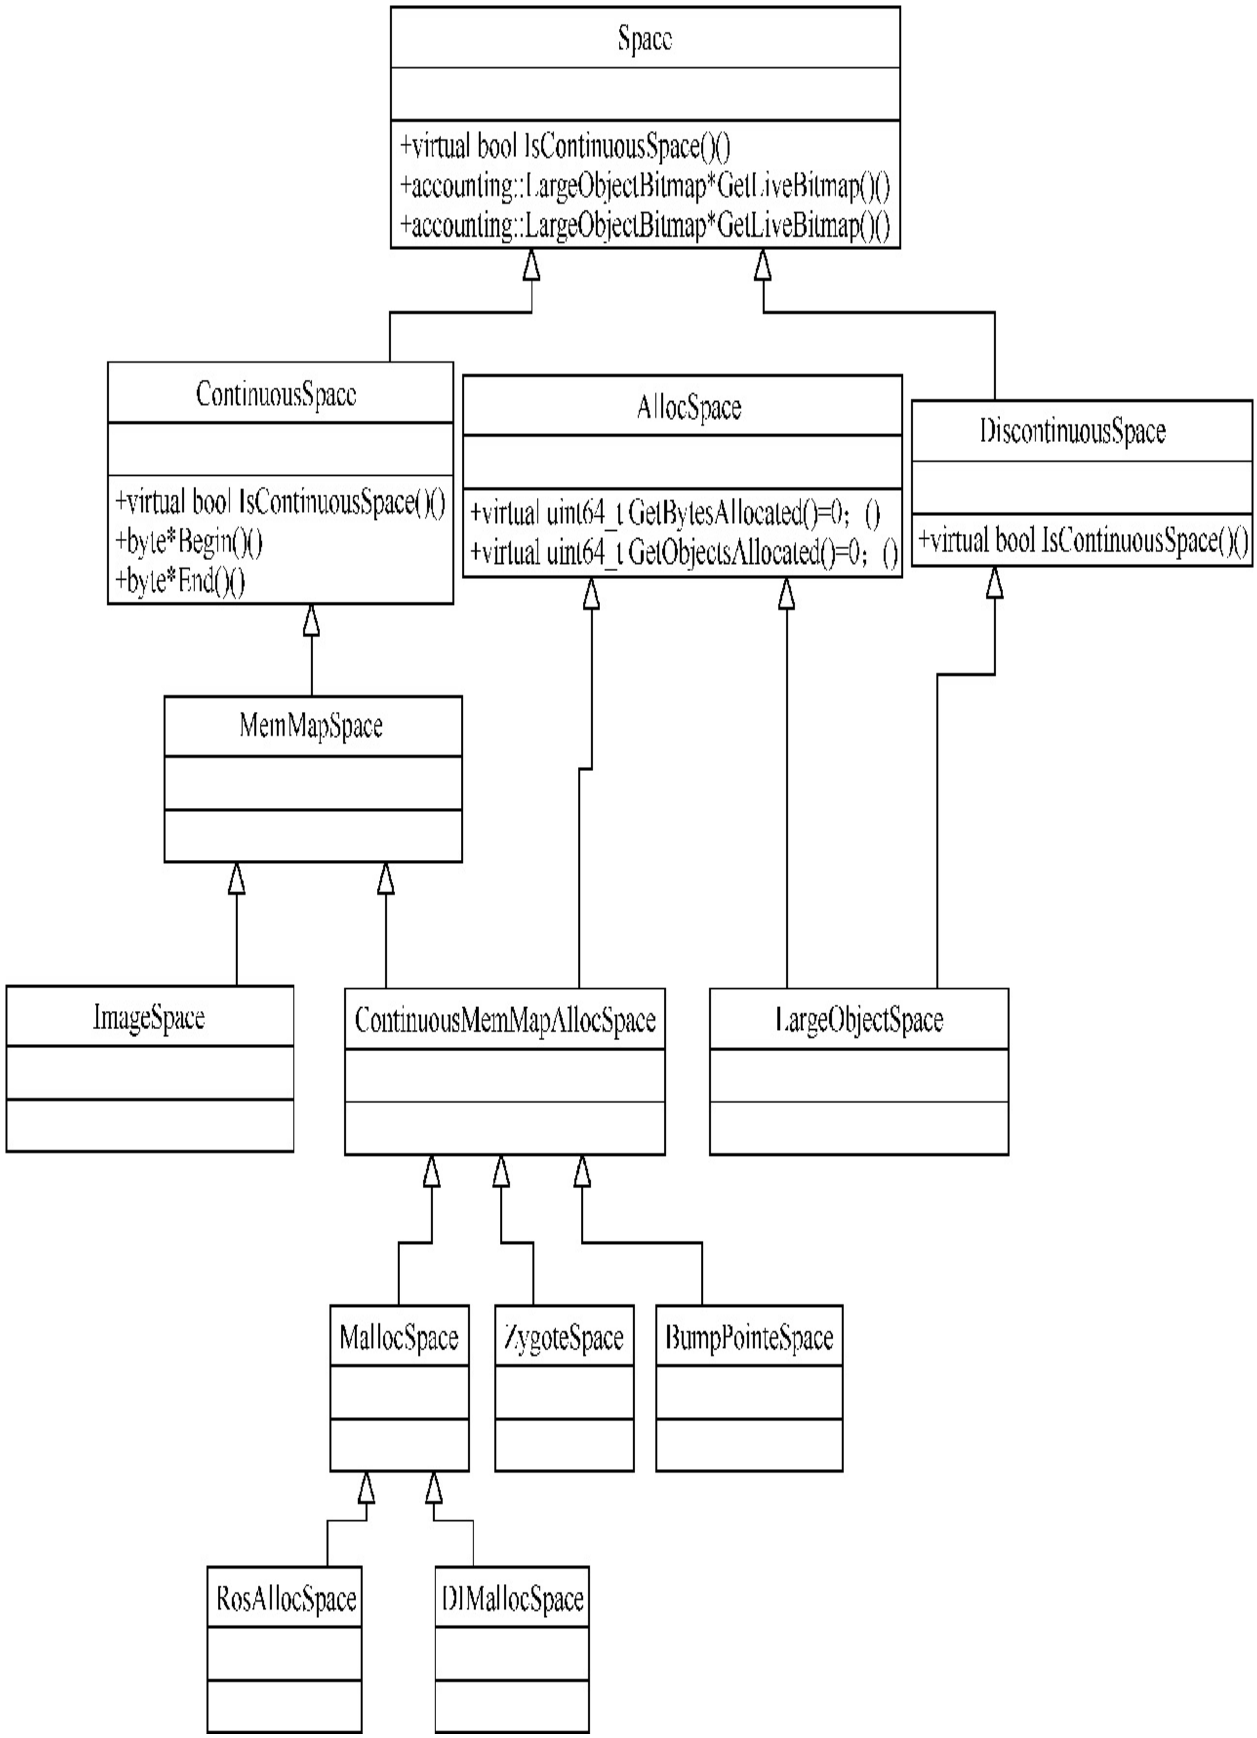
Space
+virtual bool IsContinuousSpace()()
+accounting::LargeObjectBitmap*GetLiveBitmap()()
+accounting::LargeObjectBitmap*GetLiveBitmap()()
ContinuousSpace
+virtual bool IsContinuousSpace()()
+byte*Begin()()
+byte*End()()
AllocSpace
+virtual uint64_t GetBytesAllocated()=0; ()
+virtual uint64_t GetObjectsAllocated()=0; ()
DiscontinuousSpace
+virtual bool IsContinuousSpace()()
MemMapSpace
ImageSpace
ContinuousMemMapAllocSpace
LargeObjectSpace
MallocSpace
ZygoteSpace
BumpPointeSpace
RosAllocSpace
DlMallocSpace

▲图21-54　各种Space类的继承关系

最顶层的类有两种，即Space和AllocSpace。前者提供了与“存储空间”有关的属性，而AllocSpace则负责对象的分配管理。如果把上述的关系图理解为非严格意义上的“树”，那么其树叶节点则由ImageSpace、RosAllocSpace、DlMallocSpace等元素组成——这些元素才是Space的真正载体。Space.h中专门为它们分配了对应的类型值，如下所示：

```
enum SpaceType {
  kSpaceTypeImageSpace,               ImageSpace
  kSpaceTypeMallocSpace,              DlMallocSpace
  kSpaceTypeZygoteSpace,              ZygoteSpace
  kSpaceTypeBumpPointerSpace,         BumpPointerSpace
  kSpaceTypeLargeObjectSpace,         LargeObjectSpace
};
```

这么多类型的Space对象，它们在Android虚拟机运行时环境中的内存布局是怎么样的呢？解答这个问题的办法是阅读Heap::Heap构造函数的代码实现，答案如下：

（1）ImageSpace后面紧跟着的是与它对应的Oat文件。

（2）如果separate_non_moving_space（代表我们需要单独的non moving space）为true，则分为两种情况：其一是当前进程为Zygote，那么此时Non moving space的起点是Zygote Space；否则就是单纯的non moving space。

（3）如果上述的separate_non_moving_space为true，那么接下来的Space的起始地址是低地址空间（300M）。Other spaces需要根据垃圾回收器的类型而定，例如kCollectorTypeCC对应的是Region Space。

（4）用于分配内存的核心区域叫做MainSpace，它的类型属于RosAllocSpace或者DlMallocSpace。

还有一个问题相信也是大家所关心的——即这些Space中提供的存储空间究竟从何而来，又是在什么时候申请得到的呢？

以ImageSpace为例，它是Runtime::Init创建Heap对象时，由后者

在构造过程中同步生成的。下面我们重点分析一下这个流程：

```
/*art/runtime/gc/heap.cc*/
    for (size_t index = 0; index < image_file_names.size(); ++in
      std::string& image_name = image_file_names[index];
      std::string error_msg;
      space::ImageSpace* boot_image_space = space::ImageSpace::Cr
          image_name.c_str(),
          image_instruction_set,
          index > 0,
          &error_msg);
```

Android N版本中支持多个image文件，这一点从image_file_names这个vector也可以看出来。对于image_file_names中的每一个元素，我们通过CreateBootImage来生成它们对应的Boot Image。CreateBootImage函数很长，但真正生成Image的地方在于它调用的Init函数，因而我们重点讲解一下后者（分段阅读）：

```
/*art/runtime/gc/space/Image_space.cc*/
ImageSpace* ImageSpace::Init(const char* image_filename,
                        const char* image_location,
                        bool validate_oat_file,
                        const OatFile* oat_file,
                        std::string* error_msg) {
  …
  std::unique_ptr<File> file;
  {
    TimingLogger::ScopedTiming timing("OpenImageFile", &logger);
    file.reset(OS::OpenFileForReading(image_filename));
    …
  }
  ImageHeader temp_image_header;
  ImageHeader* image_header = &temp_image_header;
  {
    TimingLogger::ScopedTiming timing("ReadImageHeader", &logger)
    bool success = file->ReadFully(image_header, sizeof(*image_he
    …
  }
  …
  const auto& bitmap_section =
               image_header->GetImageSection(ImageHeader::kSect
  const size_t image_bitmap_offset = RoundUp(sizeof(ImageHeader)
                                    image_header->GetDataSize(),
  const size_t end_of_bitmap = image_bitmap_offset + bitmap_secti
  if (end_of_bitmap != image_file_size) {…
    return nullptr;
```

```
}
```

首先要做的是打开Image文件（多数情况下以.art为后缀名），然后提取Header头部。我们在前面小节曾经简单介绍过Image Header，它包含的信息很多——比如Image内容区域和其对应的Oat区域的起始地址、所占的空间大小、是否支持PIC（Position Independent Code）等。在这个场景中我们主要想获取如下这些信息：

- image_begin_和image_size_

这两个值可以通过image_header.GetImageBegin()和image_header.GetImageSize()获得，前者表示Image文件期望的内存映射地址，后者则是映射的区域大小。

- image_bitmap_offset_和image_bitmap_size_

Bitmap是什么？它用于描述Image Space中各个对象的“存活”信息，是GC垃圾回收器的工作基础之一。不过Image Space比较特殊，它是不需要进行垃圾回收操作的（类型为kGcRetentionPolicyNeverCollect），所以理论上并不需要像其他类型的Space那样提供Live Bitmap和Mark Bitmap两类Bitmap。

Image内部会被分为7个Section，定义如下：

```
enum ImageSections {
  kSectionObjects,
  kSectionArtFields,
  kSectionArtMethods,
  kSectionDexCacheArrays,
  kSectionInternedStrings,
  kSectionClassTable,
  kSectionImageBitmap,
  kSectionCount,  // Number of elements in enum.
};
```

通过GetImageSection（ImageHeader::kSectionImageBitmap）得到的是一个Bitmap区，它主要用于垃圾回收过程。从上面的enum值可知，这个区域位于Image文件的尾部：

```
std::vector<uint8_t*> addresses(1, image_header->GetImageBegin(
if (image_header->IsPic()) {//支持位置无关特性
```

```
    // Can also map at a random low_4gb address since we can relo
    addresses.push_back(nullptr);
  }

  std::unique_ptr<MemMap> map;
  std::string temp_error_msg;
  for (uint8_t* address : addresses) {
    TimingLogger::ScopedTiming timing("MapImageFile", &logger);
    std::string* out_error_msg = (address == addresses.back()) ? 
    const ImageHeader::StorageMode storage_mode = image_header->G
    if (storage_mode == ImageHeader::kStorageModeUncompressed) {
      map.reset(MemMap::MapFileAtAddress(address,
                                        image_header->GetImageSize(),
                                        PROT_READ | PROT_WRITE,
                                        MAP_PRIVATE,
                                        file->Fd(),
                                        0,
                                        /*low_4gb*/true,
                                        /*reuse*/false,
                                        image_filename,
                                        /*out*/out_error_msg));
    } else {…
    }
    if (map != nullptr) {//按优先级来处理，一旦成功就没有必要尝试后续的ad
      break;
    }
  }
  …
```

得到了Image Header以后，接下来就可以考虑它的内容区域了。要完成的任务也很好理解，实际上就是把Image“有用”的内容读取到内存中来，以便后续直接访问使用。和普通文件不同的是，Image是被直接映射到内存中的，因而并不需要繁琐的初始化过程。这同时也是它能加速应用程序启动速度的秘诀所在。

MapFileAtAddress的第一个参数是Image希望被映射到的内存地址，这个值优先取Image Header中设定的image_begin_——因为采用这个地址将Image映射到内存中来，意味着后面我们就不需要为它的内部地址引用做很多修正工作了，所以相对而言效率会高一些。如果Image支持PIC的话，我们也可以考虑把它map到low_4gb内的任何地址上。上述代码段中的for循环会根据addresses中存储的元素逐一尝试MapFileAtAddress，一旦有一个成功的话就不用再考虑后续低优先级的address了。另外，Image目前支持多种存储方式，即

kStorageModeUncompressed（不压缩）、kStorageModeLZ4和kStorageModeLZ4HC（后面这两种都采用了LZ4无损压缩技术，它的优点在于压缩和解压缩过程的速度都相当快。具体可以参考https://code.google.com/p/lz4/）。

接下来MapFileAtAddress会进一步调用MapInternal，而后者最终则是通过mmap来完成对Image的内存映射操作。真正的映射地址，以及其他相关信息都会被封装在一个新创建的MemMap中，并传递给上述代码段中的map变量：

```
DCHECK_EQ(0, memcmp(image_header, map->Begin(), sizeof(ImageHea

std::unique_ptr<MemMap> image_bitmap_map(MemMap::MapFileAtAddre
                                                       bitmap_se
                                                       PROT_READ
                                                       file->Fd(
                                                       image_bit
                                                       /*low_4gb
                                                        /*reuse*
                                                        image_fi
                                                        error_ms
..
{
  TimingLogger::ScopedTiming timing("RelocateImage", &logger);
  if (!RelocateInPlace(*image_header,
                       map->Begin(),
                       bitmap.get(),
                       oat_file,
                       error_msg)) {
    return nullptr;
  }
}
// We only want the mirror object, not the ArtFields and ArtMet
std::unique_ptr<ImageSpace> space(new ImageSpace(image_filename
                                          image_location,
                                          map.release(),
                                          bitmap.release(),
                                          image_end));
…
Runtime* runtime = Runtime::Current();
CHECK_EQ(oat_file != nullptr, image_header->IsAppImage());
if (image_header->IsAppImage()) {…
} else if (!runtime->HasResolutionMethod()) {
  runtime->SetInstructionSet(space->oat_file_non_owned_->
                             GetOatHeader().GetInstructionSet()
```

```
    runtime->SetResolutionMethod(image_header->
                               GetImageMethod(ImageHeader::kResol
    …
  }
  …
  return space.release();
}
```

提醒大家注意的是，上述代码段中共出现了两个MemMap，分别用于映射Image和Bitmap。前面我们介绍过，假如Image被映射到的内存地址取的是Image Header中设定的image_begin_，那么就不需要做额外的重定位工作——此时RelocateInPlace经过判断后会直接返回。

另外，Boot Image中还包含很多公共的函数（例如Resolution Method、CalleeSave Method）和配置（Instruction Set），它们也都需要被提取并保存到Runtime中，以保证后续程序代码的正确执行。

到目前为止，我们分析的都是Image文件已经存在的情况下的处理过程，那么如果是Image文件缺失的情况呢？这时候就涉及Image的产生过程了（这样一来下一次就可以直接使用Image来加快速度了），即GenerateImage的实现：

```
/*art/runtime/gc/space/Image_space.cc*/
static bool GenerateImage(const std::string& image_filename, Inst
                      std::string* error_msg) {
  const std::string boot_class_path_string(Runtime::Current()->Ge
  std::vector<std::string> boot_class_path;
  Split(boot_class_path_string, ':', boot_class_path);//boot clas
  if (boot_class_path.empty()) {//Boot Class Path不存在，无法生成Ima
    *error_msg = "Failed to generate image because no boot class
    return false;
  }
  if (Runtime::Current()->IsZygote()) {//当前如果是Zygote进程的话，清
    LOG(INFO) << "Pruning dalvik-cache since we are generating an
need to recompile";
    PruneDexCache(image_isa);
  }

  std::vector<std::string> arg_vector;

  std::string dex2oat(Runtime::Current()->GetCompilerExecutable()
  arg_vector.push_back(dex2oat);

  std::string image_option_string("--image=");
```

```
  image_option_string += image_filename;
  arg_vector.push_back(image_option_string);

  for (size_t i = 0; i < boot_class_path.size(); i++) {
    arg_vector.push_back(std::string("--dex-file=") + boot_class_
  }

  std::string oat_file_option_string("--oat-file=");
  oat_file_option_string +=
                      ImageHeader::GetOatLocationFromImageLocatio
  arg_vector.push_back(oat_file_option_string);

  Runtime::Current()->AddCurrentRuntimeFeaturesAsDex2OatArguments
  …
  return Exec(arg_vector, error_msg);//运行dex2oat程序来生成Image文件
}
```

在生成Image之前首先要确定系统指定了哪些Boot Class Path。从名称上不难看出，这些路径既是Image的“输入源”，也是与“Boot”息息相关的——换句话来说，它是为大部分应用程序所共用的“Class”的集合地。

那么Boot Class Path是在哪里指定的呢？通常情况下，Runtime::Init会把正确的值保存到Runtime对象内部的成员变量boot_class_path_string_中（上述代码段中GetBootClassPathString函数返回的就是这个变量）。而Runtime会根据以下两点来确定出Boot Class Path的具体值：

- 环境变量BOOTCLASSPATH；
- 虚拟机调用者通过“-Xbootclasspath:”参数特别指定的Boot Class Path。

而且后者的优先级（如果存在的话）要高于前者，这就好比是司机首先得遵守交警的现场指挥一样。不过需要注意的是，如果当前有可用的Boot Image，那么Boot Class Path将直接来源于它，而不会再重新计算。

Android旧版本中，环境变量BOOTCLASSPATH通常会在init.rc或者其import的rc文件中被export到系统中；最新的Android版本中对此进行了调整，改由编译系统来完成这个任务。具体而言，Android系统工程/system/core/rootdir目录下的Android.mk会在

PRODUCT_BOOTCLASSPATH这个变量发生改变时重新生成init.environ.rc文件。而后者实际上又是由init.environ.rc.in这个模板文件加上一些必要的处理步骤创建出来的，例如：

```
# set up the global environment
on init
    export ANDROID_BOOTLOGO 1
    export ANDROID_ROOT /system
    export ANDROID_ASSETS /system/app
    export ANDROID_DATA /data
    export ANDROID_STORAGE /storage
    export ASEC_MOUNTPOINT /mnt/asec
    export LOOP_MOUNTPOINT /mnt/obb
    export BOOTCLASSPATH %BOOTCLASSPATH%
    export SYSTEMSERVERCLASSPATH %SYSTEMSERVERCLASSPATH%
```

Android.mk会根据当前的实际情况填充“BOOTCLASSPATH”和“SYSTEMSERVERCLASSPATH”的具体值，然后导出到init.environ.rc文件中。那么PRODUCT_BOOTCLASSPATH中包含哪些必要的路径呢？

```
/*build/core/dex_preopt.mk*/
DEXPREOPT_BOOT_JARS := $(subst $(space),:,$(PRODUCT_BOOT_JARS))
DEXPREOPT_BOOT_JARS_MODULES := $(PRODUCT_BOOT_JARS)
PRODUCT_BOOTCLASSPATH := $(subst $(space),:,
$(foreach m,$(DEXPREOPT_BOOT_JARS_MODULES),/system/framework/$(m)
```

从上面这段脚本的处理逻辑来看，PRODUCT_BOOTCLASSPATH最终需要依赖于PRODUCT_BOOT_JARS才能得到正确的结果。PRODUCT_BOOT_JARS属于产品类属性，典型的范例如下：

```
PRODUCT_BOOT_JARS := \
    core-libart \
    conscrypt \
    okhttp \
    core-junit \
    bouncycastle \
    ext \
    framework \
    telephony-common \
    voip-common \
    ims-common \
…
```

其中framework包含了各种API的真实的实现（开发者在编译时使用到的android.jar事实上只是一个空的Stub实现，更多细节可以参考本书SDK章节）；而core-libart对应的是AOSP工程目录下的libcore目录，是基础能力的集合。早期Dalvik版本中对它的命名是“core.jar”，所以Art虚拟机在初始化时如果发现BOOTCLASS仍沿用了这个文件名的话，会自动将其替换为“core-libart”（具体实现在ParsedOptions::Parse中）。

Android N版本中引入了OpenJDK，所以AOSP/libcore下面的编译主要分为两部分：

- openjdk_java_files

即与openjdk相关的文件，有一个名为openjdk_java_files.mk的脚本与之对应，主要包括了AOSP/libcore/ojluni目录下的内容。通过openjdk_java_files、non_openjdk_java_files和icu4j可以编译出名为core-all的Java包。

- non_openjdk_java_files

与非openjdk相关的文件，有一个名为non_openjdk_java_files.mk的脚本与之对应，主要包括了AOSP/libcore/dex、AOSP/libcore/luni、AOSP/libcore/dalvik几个目录下的内容。上述的core-libart就是由non_openjdk_java_files和icu4j相关的一系列文件编译而成的。

另外，PRODUCT_BOOTCLASSPATH会负责将PRODUCT_BOOT_JARS中的各个jar文件组成“/system/framework/[JAR_NAME].jar”序列，并且保证各个jar之间以“：”为分隔符,从而形成最终的结果。

理解了Boot Class Path的赋值过程后，我们继续分析前述的GenerateImage函数。因为Boot Class Path以冒号为分隔符，所以GenerateImage通过这个关键词就可以把所有路径解析成vector对象，即boot_class_path——如果这个变量为空的话，说明当前并没有指定启动类路径，那么会导致程序出错返回。另外，假如当前进程是Zygote，那么在dalvik-cache下生成新的Image之前，我们会首先调用PruneDexCache来清理掉一些“垃圾”。

接下来该dex2oat出场了。第一步自然还是要找到dex2oat程序的存储路径，即GetCompilerExecutable。默认情况下，dex2oat在设备中的位置是/system/bin/dex2oat（非调试版本）或者/system/bin/dex2oatd（调试版本）。查找到的结果将会被保存到arg_vector这个变量中，其他需要被保存的重要参数及它们的值分别是:

- “--image=”

由image_filename指定，即前面所述的boot.art的存储路径。

- “--dex-file=”

boot_class_path中的每个jar都会通过--dex-file单独传递给dex2oat程序。

- “--oat-file=”

通过GetOatLocationFromImageLocation从image文件中提取出Oat文件的路径，提取过程简单来讲就是把Image路径结尾的3个字符改为“oat”。换句话说，“--oat-file”默认情况下得到的结果值是“/system/framework/boot.oat”。

这些参数中的“--dex-file=”是dex2oat的“输入”参数，其他两个则属于“输出”参数。我们特别强调这点，是因为根据经验来看不少开发人员都容易在这个问题上“栽跟头”。

GenerateImage函数的最后会调用Exec来执行dex2oat程序，这个函数也是我们需要关注的:

```
/*art/runtime/utils.cc*/
bool Exec(std::vector<std::string>& arg_vector, std::string* erro
  …
  const char* program = arg_vector[0].c_str();//将arg_vector转化为
  std::vector<char*> args;
  for (size_t i = 0; i < arg_vector.size(); ++i) {
    …/*转化过程*/
  }
  args.push_back(NULL);
```

```
  //fork一个进程来执行dex2oat程序
  pid_t pid = fork();//孵化出一个新进程
  if (pid == 0) {//子进程
    setpgid(0, 0);//设置group id
    execv(program, &args[0]);//执行dex2oat程序
    PLOG(ERROR) << "Failed to execv(" << command_line << ")";
    exit(1);
  } else {
    if (pid == -1) {//进程孵化失败
      *error_msg = StringPrintf("Failed to execv(%s) because fork
                                command_line.c_str(), strerror(er
      return false;
    }
    int status;
    pid_t got_pid = TEMP_FAILURE_RETRY(waitpid(pid, &status, 0));
    if (got_pid != pid) {
      *error_msg = StringPrintf("Failed after fork for execv(%s)
                              "wanted %d, got %d: %s",
                              command_line.c_str(), pid, got_pid,
      return false;
    }
    if (!WIFEXITED(status) || WEXITSTATUS(status) != 0) {
      *error_msg = StringPrintf("Failed execv(%s) because non-0 e
                                command_line.c_str());
      return false;
    }
  }
  return true;
}
```

这个函数的实现逻辑并不复杂。首先是逐一处理函数入参arg_vector中的所有元素，除了将它们转化为char*指针外，还需要保存到args这个新的vector中。

接下来通过Linux中创建新进程的经典方式——fork来孵化出dex2oat的承载进程。其中pid==0的情况属于新孵化出的子进程，在这个分支中我们会调用execv来加载和运行目标程序（即dex2oat），并由后者完成Image和Oat文件的生成工作。

同时父进程也会继续运行。因为fork函数是在父进程中被调用的，所以它的返回值自然在这一环境中是可见的。换句话说，代表dex2oat所在进程的pid值不会是0：如果是-1的话，表示fork函数执行失败；否则pid就代表了dex2oat的进程id号。那么父进程中应该承担哪些工作呢？答案是：等待。具体来说就是调用waitpid主动等待dex2oat完成任

务，再根据这个程序的运行结果来决定最终结果是false（失败）或者true（成功）。

所以总结来说，dex2oat既可以被用于编译Oat，还担负着生成Image的责任。

21.7 Android虚拟机中的线程管理

我们知道，Android虚拟机是支持多线程的。那么虚拟机中的线程是如何管理（重点关注创建和挂起两个核心流程）的，和Linux线程又有什么区别和联系呢？这些我们本小节所要回答的问题。

21.7.1 Java线程的创建过程

我们知道，Java代码中可以通过多种方式来创建一个线程，比如下面这种典型的做法：

```
Thread thread= new Thread();
```

Thread提供了不同的构造函数来满足开发者的各种场景需求，不过它们最终都会调用同一个Create函数：

```
  /*libcore/libart/src/main/java/java/lang/Thread.java*/
  public Thread() {
        create(null, null, null, 0);
}
```

大家需要注意的是，此时新的线程其实还没有被创建出来——这要等到Thread.Start()时才生效：

```
    public synchronized void start() {
        checkNotStarted();
        hasBeenStarted = true;
        nativeCreate(this, stackSize, daemon);
    }
```

其中nativeCreate是一个本地层的函数，如下所示：

```
/*art/runtime/native/java_lang_Thread.cc*/
static void Thread_nativeCreate(JNIEnv* env, jclass, jobject java
                                jlong stack_size, jboolean daemon
  Thread::CreateNativeThread(env, java_thread, stack_size, daemon
}
```

很明显，Java层的Thread类最终关联的是native层中的Thread.cc：

```
/*art/runtime/Thread.cc*/
void Thread::CreateNativeThread(JNIEnv* env, jobject java_peer, s
  CHECK(java_peer != nullptr);
  Thread* self = static_cast<JNIEnvExt*>(env)->self;
  Runtime* runtime = Runtime::Current();

  // Atomically start the birth of the thread ensuring the runtim
  bool thread_start_during_shutdown = false;
  {
    MutexLock mu(self, *Locks::runtime_shutdown_lock_);
    if (runtime->IsShuttingDownLocked()) {
      thread_start_during_shutdown = true;
    } else {
      runtime->StartThreadBirth();
    }
  }
  …
  Thread* child_thread = new Thread(is_daemon);//创建新线程类
  …
  pthread_t new_pthread;
  pthread_attr_t attr;
  CHECK_PTHREAD_CALL(pthread_attr_init, (&attr), "new thread");
  CHECK_PTHREAD_CALL(pthread_attr_setdetachstate, (&attr, PTHREAD
  CHECK_PTHREAD_CALL(pthread_attr_setstacksize, (&attr, stack_siz
  int pthread_create_result = pthread_create(&new_pthread, &attr,
 Thread::CreateCallback, child_thread);
  …
}
```

StartThreadBirth和EndThreadBirth需要配套使用，用于表示当前有新线程在“孵化”中，这点我们在Runtime::Init分析main线程的创建时就已经描述过了。接下来会创建一个新的线程类Thread，不过这时还未fork出一个线程。真正的转折点出现在pthread_create函数中，它是由pthread提供的标准的线程创建接口（这也意味着，Java程序中的线程是由操作系统线程来承载的）。声明如下：

```
int pthread_create(pthread_t *tidp,const pthread_attr_t *attr, (v
               void *arg);
```

第1个参数代表的是指向线程标志符的指针；第2个参数是线程的属性值；第3个参数代表这个新线程的入口地址，在这个场景中传入的是Thread::CreateCallback；最后的arg变量是新线程的入口函数所需要的参数。

新的线程孵化出来以后，系统会主动调用它所提供的入口函数，如下所示：

```
/*art/runtime/Thread.cc*/
void* Thread::CreateCallback(void* arg) {//arg即Thread类对象
  Thread* self = reinterpret_cast<Thread*>(arg);
  Runtime* runtime = Runtime::Current();//一个进程中只存在唯一的Runti
  …
  {
    …
    CHECK(!runtime->IsShuttingDownLocked());
    self->Init(runtime->GetThreadList(), runtime->GetJavaVM());
    Runtime::Current()->EndThreadBirth();
  }
  {
    ScopedObjectAccess soa(self);

    // Copy peer into self, deleting global reference when done.
    CHECK(self->tlsPtr_.jpeer != nullptr);
    self->tlsPtr_.opeer = soa.Decode<mirror::Object*>(self->tlsPt
    self->GetJniEnv()->DeleteGlobalRef(self->tlsPtr_.jpeer);
    self->tlsPtr_.jpeer = nullptr;
    self->SetThreadName(self->GetThreadName(soa)->ToModifiedUtf8(
    Dbg::PostThreadStart(self);

    // Invoke the 'run' method of our java.lang.Thread.
    mirror::Object* receiver = self->tlsPtr_.opeer;
    jmethodID mid = WellKnownClasses::java_lang_Thread_run;
    InvokeVirtualOrInterfaceWithJValues(soa, receiver, mid, nullp
  }
  // Detach and delete self.
  Runtime::Current()->GetThreadList()->Unregister(self);//线程生命

  return nullptr;
}
```

执行到上述这个函数时，我们就已经“摆脱”了原先的旧线程，进入新的“征程”了。那么刚创建的线程需要完成哪些核心工作呢？

（1）毋庸置疑，它首先需要被纳入虚拟机的统一管理中，完成这个任务的是self->Init。

（2）为下面第3点中的函数调用准备好所需参数，更确切地说就是指receiver和mid。其中mid代表了某个特定Java函数的唯一ID号。在我们这个场景中，它被赋予的值是WellKnownClasses::

java_lang_Thread_run（WellknownClasses如其名称所示，代表了一些常用的基础类，以及基础类中包含的成员函数、变量的集合，譬如java.lang.Thread、java.lang.ClassLoader、dalvik.system.VMRuntime等。它们都在Well_known_classes中以static变量的形式存在）。WellknownClasses在完成自身初始化的同时，也会为其负责的所有常用类逐一做初始化工作。以java_lang_Thread_run这个常用类为例，它的初始化过程如下所示：

```
/*art/runtime/well_known_classes.cc*/
void WellKnownClasses::Init(JNIEnv* env) {…
  java_lang_Thread = CacheClass(env, "java/lang/Thread");
  …
  java_lang_Thread_run = CacheMethod(env, java_lang_Thread, false
  …
```

在分析Cache的实现之前，我们先来思考一下，WellKnownClasses的Init函数应该由谁来调用呢？我们前面已经提过，JNIEnv是线程相关的，也就是说每个线程都有自己的JNI环境。换句话说，虚拟机中有哪个线程需要负责加载java.lang.Thread这样的常用类呢？

没错，是主线程。具体的调用流程是Runtime::Start ->Runtime::InitNativeMethods-> WellKnown Classes::Init，有兴趣的读者可以自行分析源码了解详情。

接下来我们继续分析CacheClass的实现：

```
/*art/runtime/well_known_classes.cc*/
static jclass CacheClass(JNIEnv* env, const char* jni_class_name)
  ScopedLocalRef<jclass> c(env, env->FindClass(jni_class_name));
  if (c.get() == nullptr) {
    LOG(FATAL) << "Couldn't find class: " << jni_class_name;
  }
  return reinterpret_cast<jclass>(env->NewGlobalRef(c.get()));
}
```

不难发现，查找Class的重任落在env->FindClass这个函数上面。其中env代表的是一个JNI运行环境，它是线程相关的。这个场景中的env来源于self->GetJniEnv()，而self是Runtime对象通过Thread::Current()获取的，也就是Runtime自身所在的线程。GetJniEnv得到的是一个继承自JNIEnv(它是对_JNIEnv的typedef)的JNIEnvExt，它的成员函数FinClass的定义如下：

```
/*art/libnativehelper/jni.h*/
struct _JNIEnv {
    /* do not rename this; it does not seem to be entirely opaque
    const struct JNINativeInterface* functions;
    …
    jclass FindClass(const char* name)
    { return functions->FindClass(this, name); }
```

functions会在JNIEnvExt构造时被指定为一个全局的函数列表，如下所示：

```
/*art/runtime/jni_env_ext.cc*/
JNIEnvExt::JNIEnvExt(Thread* self_in, JavaVMExt* vm_in)…{
  functions = unchecked_functions = GetJniNativeInterface();
  …
}
```

GetJniNativeInterface 返回的是一个全局变量gJniNativeInterface，这个列表中指向的是jni_internal文件中的函数，其中FindClass的最终实现如下：

```
/*art/runtime/jni_internal.cc*/
static jclass FindClass(JNIEnv* env, const char* name) {
    CHECK_NON_NULL_ARGUMENT(name);
    Runtime* runtime = Runtime::Current();
    ClassLinker* class_linker = runtime->GetClassLinker();
    std::string descriptor(NormalizeJniClassDescriptor(name));
    ScopedObjectAccess soa(env);
    mirror::Class* c = nullptr;
    if (runtime->IsStarted()) {
      StackHandleScope<1> hs(soa.Self());
      Handle<mirror::ClassLoader> class_loader(hs.NewHandle(GetCl
      c = class_linker->FindClass(soa.Self(), descriptor.c_str(),
    } else {
      c = class_linker->FindSystemClass(soa.Self(), descriptor.c_
    }
    return soa.AddLocalReference<jclass>(c);
  }
```

从这个函数可以看到，函数的查找过程最终是由Class Linker来负责的，我们将在后续小节做详细介绍，现在先不赘述。

（3）执行本线程所承载的程序代码。譬如开发者在Android应用程序中通常会启动一个新的线程来从远端服务器下载文件；或者启动新线

程执行一些耗时的运算操作等。一个典型的Java线程用法是开发人员通过继承Runnable来提供新线程所需完成的功能。开发者自定义的Runnable对象会将被保存在Thread.target变量中，而后者又会在Thread::run()函数中被调用，如下所示：

```
/*libcore/libart/src/main/java/java/lang/Thread.java*/
public void run() {
    if (target != null) {
        target.run();
    }
}
```

这样一来我们就不难理解Thread::CreateCallback所要承担的主要任务了：它需要在Native层调用并执行Java层中的run()函数。所以问题就转化为CreateCallback怎么才可以找到run()所对应的Java代码，然后运行它呢？

大家应该猜到了，完成上述工作的实际执行者是InvokeVirtualOrInterfaceWithJValues：

```
/*art/runtime/reflection.cc*/
JValue InvokeVirtualOrInterfaceWithJValues(const ScopedObjectAcce
       soa, mirror::Object* receiver, jmethodID mid, jvalue* args
  …
  mirror::ArtMethod* method = FindVirtualMethod(receiver, soa.Dec
                            /*查找到正确的ArtMethod*/
  uint32_t shorty_len = 0;
  const char* shorty = method->GetShorty(&shorty_len);
  JValue result;
  ArgArray arg_array(shorty, shorty_len);
  arg_array.BuildArgArrayFromJValues(soa, receiver, args);
  InvokeWithArgArray(soa, method, &arg_array, &result, shorty);/*
  return result;
}
```

Android虚拟机提供了很多函数来帮助程序从Native层发起并调用到Java函数，例如InvokeWithArgArray、InvokeWithJValues等。从函数名称InvokeVirtualOrInterfaceWithJValues可以看出，它会试图查找并执行一个虚函数或者接口函数。输入参数中的mid代表了函数的唯一ID号；jvalue是这个函数所需的参数；另一个重要的参数变量receiver则是mid函数所归属的类。

查找过程由FindVirtualMethod完成：

```
/*art/runtime/reflection.cc*/
static ArtMethod* FindVirtualMethod(mirror::Object* receiver, Art
    SHARED_LOCKS_REQUIRED(Locks::mutator_lock_) {
  return receiver->GetClass()->FindVirtualMethodForVirtualOrInter

}
```

简单来讲，receiver->GetClass得到的是一个Class类的描述，借此才能得到它所包含的Virtual Method或者Interface；ArtMethod类是虚拟机内部对函数的描述结构。不论函数最终是通过Java解释器来执行，还是直接使用它所对应的OAT机器码来完成，都由ArtMethod来决定。

对于InvokeWithArgArray的具体实现过程，我们在后续小节还会有详细分析。

21.7.2　线程的挂起过程

虚拟机中的线程在很多场景下都需要被挂起，例如当垃圾回收器工作时（注意：并不是所有GC情况下都需要线程挂起）、程序正在等待调试器的连接等。所以学习虚拟机线程管理的一个必要环节，是了解线程的挂起过程。本小节我们将以ThreadList::SuspendAll为线索来探寻Art虚拟机是如何处理线程挂起操作的，以及大家在开发过程中又有哪些需要特别注意的地方：

```
/*art/runtime/thread_list.cc*/
void ThreadList::SuspendAll(const char* cause, bool long_suspend)
  Thread* self = Thread::Current();
  …
  {
    ScopedTrace trace("Suspending mutator threads");
    const uint64_t start_time = NanoTime();

    SuspendAllInternal(self, self);
#if HAVE_TIMED_RWLOCK
    while (true) {
      if (Locks::mutator_lock_->ExclusiveLockWithTimeout(self,
                                        kThreadSuspendTimeoutMs, 0))
        break;
      } else if (!long_suspend_) {
```

```
        UnsafeLogFatalForThreadSuspendAllTimeout();
      }
    }
#else
    Locks::mutator_lock_->ExclusiveLock(self);
#endif

    long_suspend_ = long_suspend;

    const uint64_t end_time = NanoTime();
    const uint64_t suspend_time = end_time - start_time;
    suspend_all_historam_.AdjustAndAddValue(suspend_time);
    if (suspend_time > kLongThreadSuspendThreshold) {
      LOG(WARNING) << "Suspending all threads took: " << PrettyDu
    }
    …
  }
  …
}
```

ThreadList是当前虚拟机中管理的线程的集合体，SuspendAllInternal的任务就是通知它们全部进入挂起状态。简单来讲，它采取的作法是通过给各个线程置位kSuspendRequest来请求后者进入Suspend，并将该线程对应的tlsPtr_.suspend_trigger置为无效的nullptr。这样一来当线程执行到它的Check Point访问上述变量时，就会引发SIGSEGV的段错误，从而通过预先注册的fault hander（参见前面小节的讲解）逐步执行到Suspension check的处理函数，即art_quick_implicit_suspend中。

函数art_quick_implicit_suspend是一个汇编函数，主要目的是跳转到artTestSuspendFromCode中，后者会在将过一系列调用后最终进入TransitionFromRunnableToSuspended。

TransitionFromRunnableToSuspended函数最关键的两步操作，其一是TransitionTo Suspended AndRunCheckpoints，负责把当前线程状态切换为挂起状态；其二就是Locks::mutator_lock->TransitionFromRunnableToSuspended，主要目的在于释放当前线程持有的mutator_lock_的Shared Lock。这些知识点我们在讲解信号机制时还有详细描述，这里只有了解大致处理过程就可以了。

那么系统如何判断是不是所有线程都已经挂起成功了呢？这是借助于Locks::mutator_lock_实现的。因为Darwin系统不支持带超时功能的

lock，所以需要通过HAVE_TIMED_RWLOCK宏来区分对待（除非当前系统是Apple，否则这个宏的值为1）。ThreadList::SuspendAll中的while循环的执行逻辑如下：调用ExclusiveLockWithTimeout来获取Exclusive Lock，并设置超时时间（目前为kThreadSuspendTimeoutMs=30秒）。如果线程无法在指定时间内进入挂起状态，那么ExclusiveLockWithTimeout返回false，同时如果long_suspend_不为true，那么就会引发致命错误，并调用UnsafeLogFatalForThreadSuspendAllTimeout来打印出详细的错误信息。例如下面是从Android Bug反馈系统上摘录的一个真实范例：

```
A/art: art/runtime/thread_list.cc:173] Thread suspend timeout
A/art: art/runtime/thread_list.cc:173] mutator lock level=46 owner=18446744073709551615 state=1 num_pending_writers=0

A/art: art/runtime/thread_list.cc:173] DALVIK THREADS (20):
A/art: art/runtime/thread_list.cc:173] "main" prio=5 tid=1 Native
A/art: art/runtime/thread_list.cc:173]   | group="main" sCount=1 dsCount=0 obj=0x731a5000 self=0xb3c25400
A/art: art/runtime/thread_list.cc:173]   | sysTid=1966 nice=0 cgrp=default sched=0/0 handle=0xb7723ea0
A/art: art/runtime/thread_list.cc:173]   | state=S schedstat=( 0 0 0 ) utm=12 stm=21 core=0 HZ=100
A/art: art/runtime/thread_list.cc:173]   | stack=0xbf715000-0xbf717000 stackSize=8MB
A/art: art/runtime/thread_list.cc:173]   | held mutexes=
A/art: art/runtime/thread_list.cc:173]   kernel: futex_wait_queue_me+0xc5/0xfe
A/art: art/runtime/thread_list.cc:173]   kernel: futex_wait+0xb9/0x1ca
A/art: art/runtime/thread_list.cc:173]   kernel: do_futex+0x8c/0x7a3
A/art: art/runtime/thread_list.cc:173]   kernel: sys_futex+0x88/0xdb
A/art: art/runtime/thread_list.cc:173]   kernel: syscall_call+0x7/0xb
A/art: art/runtime/thread_list.cc:173]   native: #00 pc 000132d0  /system/lib/libc.so (syscall+32)
A/art: art/runtime/thread_list.cc:173]   native: #01 pc 007fbc77  [stack] (???)
A/art: art/runtime/thread_list.cc:173]   at android.database.sqlite.SQLiteConnection.nativeExecute(Native method)
A/art: art/runtime/thread_list.cc:173]   at android.database.sqlite.SQLiteConnection.execute(SQLiteConnection.java:555)
A/art: art/runtime/thread_list.cc:173]   at
```

“Thread suspend timeout”明确指出这是因为挂起线程失败导致的问题。那么线程挂起成功与否和ExclusiveLockWithTimeout的执行过程有什么必然的联系呢？

我们知道，Locks::mutator_lock_是一个MutatorMutex指针，如下：

```
mutator_lock_ = new MutatorMutex("mutator lock", current_lock_lev
```

而且Locks::mutator_lock_又继承自ReaderWriterMutex，这就是我们在本书操作系统同步互斥章节曾专门介绍过的读写锁。它在各个状

态下所允许的操作及结果如表21-10所示。

表21-10　操作及结束

State	ExclusiveLock	ExclusiveUnlock	SharedLock	SharedUnlo
Free	Exclusive	error	SharedLock(1)	error
Exclusive	Block	Free	Block	error
Shared(n)	Block	error	SharedLock(n+1)	Shared(n-1) c Free

因为Art中的很多函数都需要mutator lock的“读取锁”，这一点我们通过搜索关键词“mutator_lock_”就可以确认了：

```
Class.h (art\runtime\mirror):  bool IsArrayClass() SHARED_REQUIRES(Locks::mutator_lock_);
Class.h (art\runtime\mirror):  bool IsClassClass() SHARED_REQUIRES(Locks::mutator_lock_);
Class.h (art\runtime\mirror):  bool IsThrowableClass() SHARED_REQUIRES(Locks::mutator_lock_);
Class.h (art\runtime\mirror):  bool IsReferenceClass() const SHARED_REQUIRES(Locks::mutator_lock_);
```

当调用上述这类函数时，一个必要的前提条件是成功获得mutator_lock_的Shared Lock，否则编译器会报错。另外获取到Exclusive Lock的前提则是所有的Shared Lock都得到释放（即Free状态），否则就会进入Block状态。换句话说，如果所有线程都可以在预定时间内进入挂起状态（各个线程申请的Shared Lock会被同步释放），那么ExclusiveLockWithTimeout就能够在Timeout之前成功返回true；否则30秒超时后任务未完成，就会引发fatal error。

通过mutator_lock_的方式可以很好地达到对虚拟机线程的挂起控制，这其中的设计实现还是蛮巧妙的，值得大家借鉴学习。

21.8　Art虚拟机中的代码执行方式综述

伴随着AOT、JIT等技术的出现，Java虚拟机的执行方式已经不单纯是“解释器”这一种了。以Art虚拟机为例，大家可以思考一下它所面对的代码环境是什么样的？

- （1）使用Java语言编写的代码

此时有如下两种情况。

Case1：Dex字节码在Interpreter中执行。

需要注意的是，Java代码在Interpreter中并不一定就是解释执行，它还可能是JIT执行。

Case2：Dex字节码经过dex2oat转化后的本地机器码的执行。

- （2）使用C/C++等语言编写的代码

Case3：使用C/C++编写的函数，通常会被编译成.so文件，并利用JNI技术参与到Android应用程序的运行中。JNI本地函数和上述的Case2都是对本地机器码的执行，所以它们存在相似之处

另外，以上3个Case并不是完全孤立的———换句话说，它们存在互相调用的情况。这无疑进一步加剧了Art的处理难度，大致如图21-55所示。

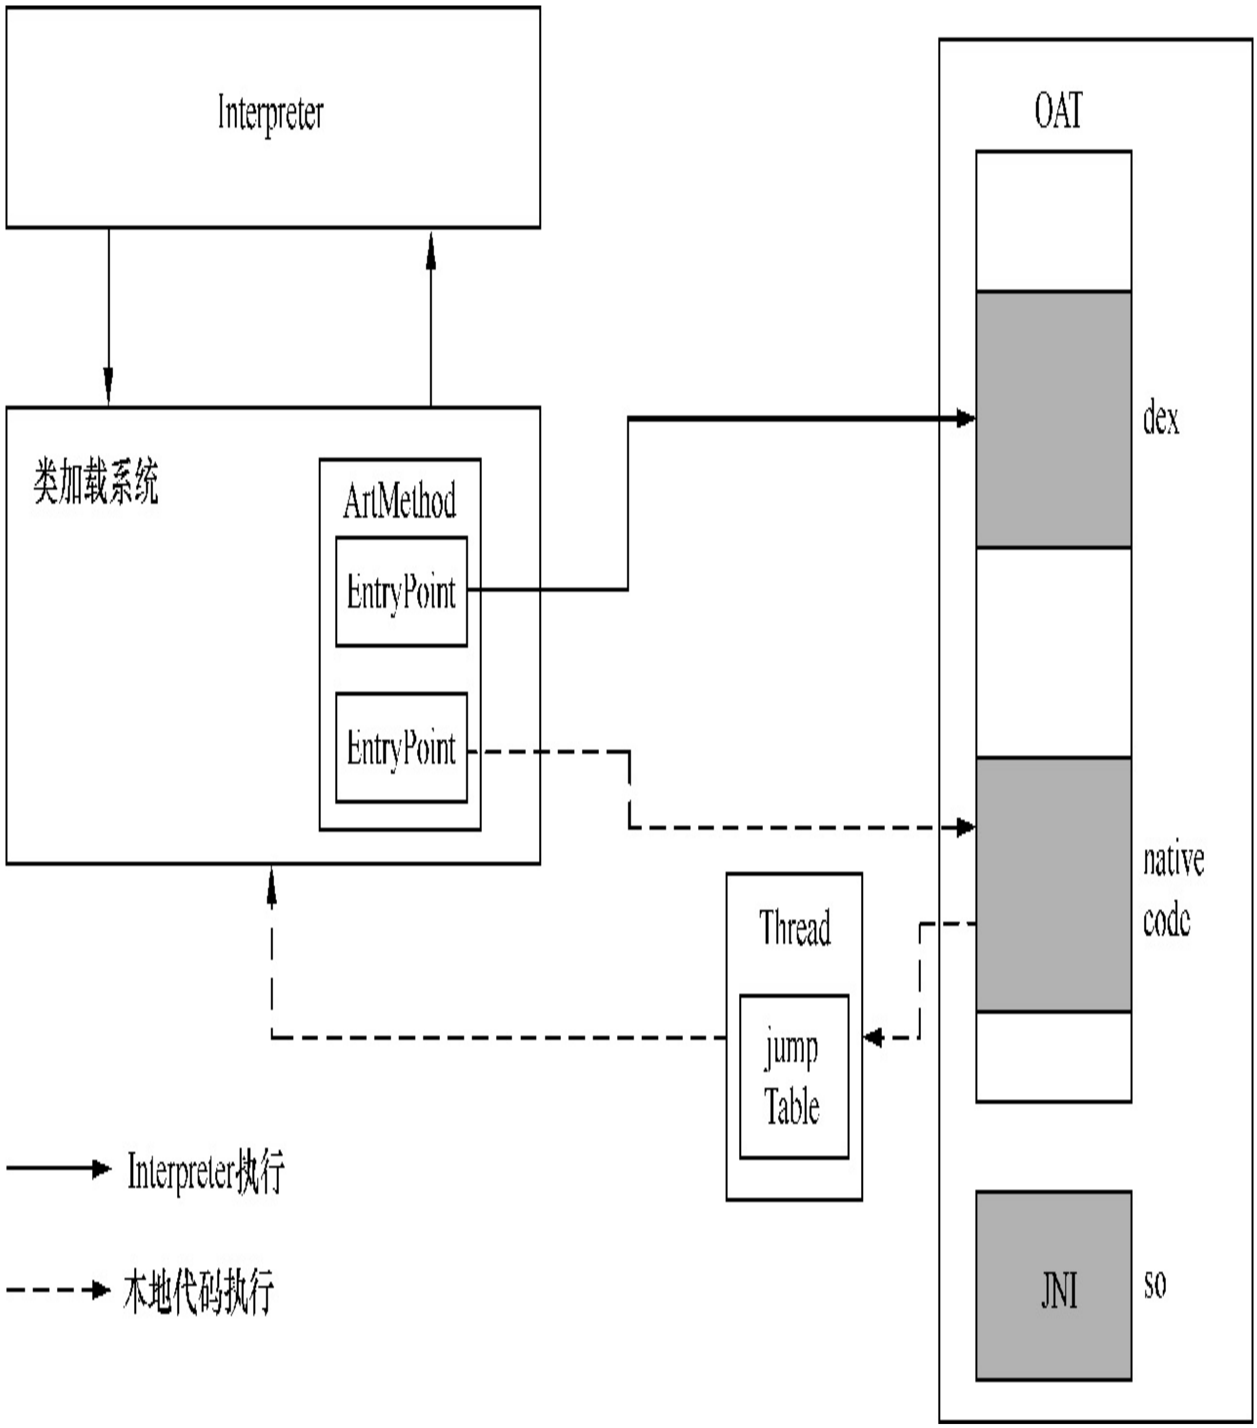

▲图21-55　Art虚拟机中的代码执行路径图示

- （1）字节码在Interpreter中的执行过程

当ArtMethod确认需要通过Interpreter来执行本函数时，将交由后者来解析执行字节码（也可能是JIT）。在此过程中如果遇到invoke-XX

命令的话，Interpreter会通过DoInvoke函数（interpreter_common.h）来查找和确定目标对象，并跳转过去。每一个目标对象都对应一个ArtMethod，查找的工作则由类加载系统完成。DoInvoke与类加载系统之间的桥梁是FindMethodFromCode，核心实现如下：

```
/*art/runtime/entrypoints/entrypoint_utils-inl.h*/
template<InvokeType type, bool access_check>
inline ArtMethod* FindMethodFromCode(uint32_t method_idx, mirror:
                                 this_object,ArtMethod* referrer,
  ClassLinker* const class_linker = Runtime::Current()->GetClassL
  ArtMethod* resolved_method = class_linker->GetResolvedMethod(me
  if (resolved_method == nullptr) {
    StackHandleScope<1> hs(self);
    mirror::Object* null_this = nullptr;
    HandleWrapper<mirror::Object> h_this(
        hs.NewHandleWrapper(type == kStatic ? &null_this : this_o
    constexpr ClassLinker::ResolveMode resolve_mode =
        access_check ? ClassLinker::kForceICCECheck
                     : ClassLinker::kNoICCECheckForCache;
  resolved_method = class_linker->ResolveMethod<resolve_mode>(sel
                                                   method_idx, re
  }
…
```

上述代码段的逻辑是：首先通过ClassLinker的GetResolvedMethod来确定系统之前是否解析过这个函数，如果答案是肯定的，就没有必要重复解析了；否则我们需要利用ResolveMethod来查找和获取目标函数。ResolveMethod的工作主要分为3个环节，即定位Dex、定位Class，最后才是定位Method。

一旦成功获取到目标函数对应的ArtMethod后，DoInvoke紧接着利用模板函数DoCall来执行ArtMethod。DoCall的实现在interpreter_common.cc中，它的职责是准备好各种arguments，然后进一步调用DoCallCommon。后者中真正去执行的ArtMethod的核心语句摘录如下：

```
…
if (LIKELY(Runtime::Current()->IsStarted())) {//Runtime已经启动完成
    ArtMethod* target = new_shadow_frame->GetMethod();
    if (ClassLinker::ShouldUseInterpreterEntrypoint(
        target, target->GetEntryPointFromQuickCompiledCode())) {
      ArtInterpreterToInterpreterBridge(self, code_item, new_shad
```

```
    } else {
      ArtInterpreterToCompiledCodeBridge(self, code_item, new_sha
    }
  } else {
    UnstartedRuntime::Invoke(self, code_item, new_shadow_frame, r
  }
```

正常情况下Runtime都已经启动完成，所以我们只要根据ShouldUseInterpreterEntrypoint的返回结果就能判断出下一步的动作——如果此函数的返回值表明执行该ArtMethod对应的函数需要使用Interpreter，那么接下来的处理就相当于从interpreter->interpreter（使用ArtInterpreter ToInterpreterBridge）；反之就说明需要进入本地代码执行，因而是interpreter->compiled code（使用ArtInterpreterToCompiledCodeBridge），如图21-56所示。

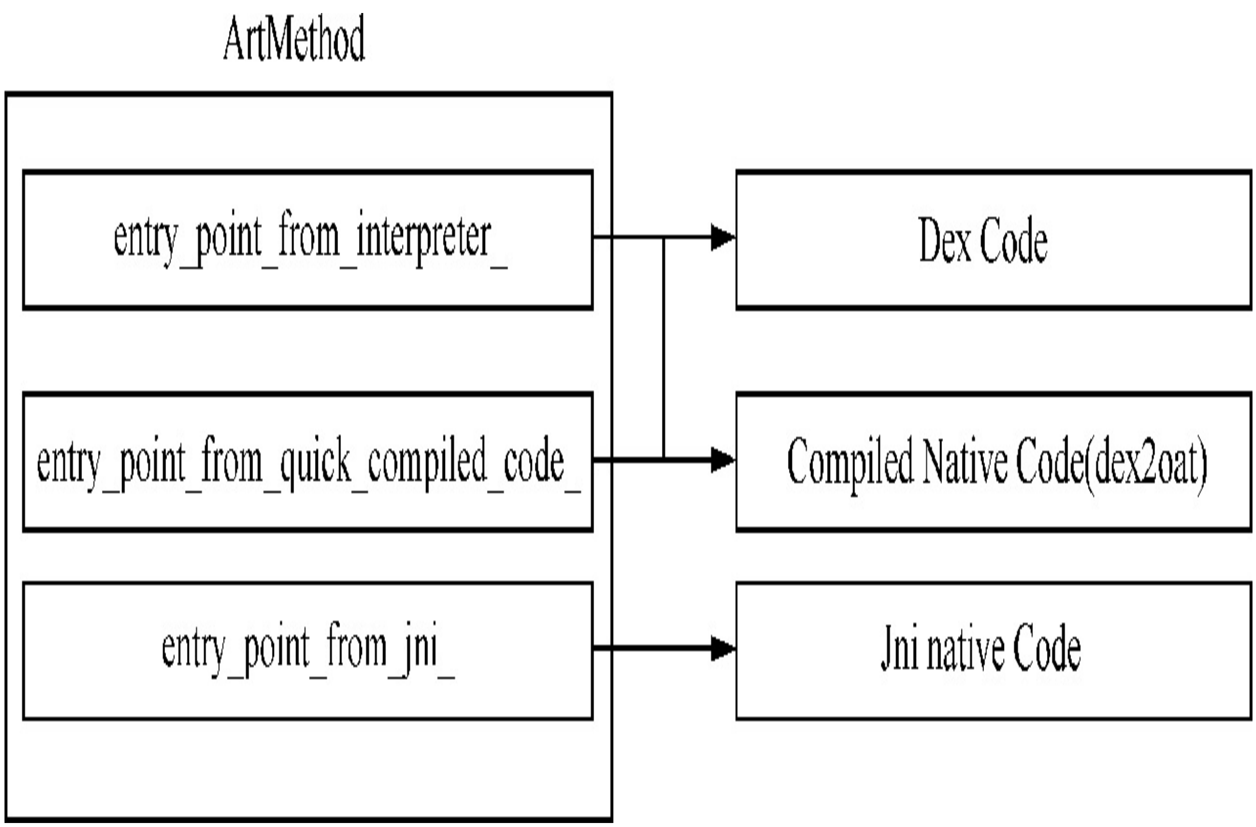

▲图21-56　ArtMethod中的EntryPoint

我们知道，ArtMethod是对Java函数（包括JNI函数和非JNI函数）的运行时抽象。如果是JNI函数，那么就应该获取到它所对应的so中的本地代码来执行；如果是非JNI函数，那么会有两种情况：即通过

Interpreter来解释执行它的字节码；或者是直接执行dex2oat后生成的Native Code。具体选择哪种方式会受到多重因素的影响，譬如当前是否处于调试状态（调试模式下需要解释执行），函数是否有对应的Oat Code（并非所有Java函数都可以编译生成Oat Code）等。值得一提的是，ArtMethod中的几个entry_point变量在Android历代版本中的改动都较大，其中entry_point_from_interpreter_在Android N版本中已经被移除并采用其他方式替代；entry_point_from_jni_成员变量如果改名为“entry_point_to_jni_”或许更能表达它的设计初衷。这些请大家在阅读源码时特别注意。

那么ArtMethod中的这些Entry Point是在什么时候被赋值的呢？答案是LinkCode：

```
/*art/runtime/class_linker.cc*/
void ClassLinker::LinkCode(ArtMethod* method, const OatFile::OatC
                           uint32_t class_def_method_index) {
  Runtime* const runtime = Runtime::Current();
  if (runtime->IsAotCompiler()) {//当前虚拟机进程是dex2oat，直接返回
    // The following code only applies to a non-compiler runtime.
    return;
  }
  // Method shouldn't have already been linked.
  DCHECK(method->GetEntryPointFromQuickCompiledCode() == nullptr)
  if (oat_class != nullptr) {
    const OatFile::OatMethod oat_method =
               oat_class->GetOatMethod(class_def_method_index
    oat_method.LinkMethod(method);//为ArtMethod指定Native Code
  }
  const void* quick_code = method->GetEntryPointFromQuickCompiled
  bool enter_interpreter = ShouldUseInterpreterEntrypoint(method,
                                //是否需要使用解释器来执行这个函数

  if (!method->IsInvokable()) {//函数允许被执行吗？譬如抽象函数
    EnsureThrowsInvocationError(method);
    return;
  }

  if (method->IsStatic() && !method->IsConstructor()) {//静态非构造
    method->SetEntryPointFromQuickCompiledCode(GetQuickResolution
  } else if (quick_code == nullptr && method->IsNative()) {//本地
    method->SetEntryPointFromQuickCompiledCode(GetQuickGenericJni
  } else if (enter_interpreter) {//需要解释执行的情况
    // Set entry point from compiled code if there's no code or i
    method->SetEntryPointFromQuickCompiledCode(GetQuickToInterpre
```

```
  }

  if (method->IsNative()) {
    // Unregistering restores the dlsym lookup stub.
    method->UnregisterNative();

    if (enter_interpreter || quick_code == nullptr) {
      const void* entry_point = method->GetEntryPointFromQuickCom
      DCHECK(IsQuickGenericJniStub(entry_point) ||
                                             IsQuickResolutionStub(entry_po
    }
  }
}
```

LinkCode中首先需要注意的就是oat_method.LinkMethod（method）这个语句，因为ArtMethod所对应的机器码就是通过这个函数获取的。我们来看一下它的代码实现：

```
/*art/runtime/oat_file.cc*/
void OatFile::OatMethod::LinkMethod(ArtMethod* method) const {
  CHECK(method != nullptr);
  method->SetEntryPointFromQuickCompiledCode(GetQuickCode());
}
```

OatMethod中包含的两个变量——即begin_和code_offset_，它们的取和结果，就是本函数对应的机器码在内存中的加载地址（后者是基于前者的偏移量）。GetQuickCode()就是根据它们来获取到QuickCode的，然后再通过ArtMethod自身的SetEntryPointFromQuickCompiledCode设置其为Compiled Native Code的入口点。

ShouldUseInterpreterEntrypoint在多种情况下会返回true：Quick Code不存在；或者程序特别约定了只能使用解释器（并且当前不能是Native和Proxy函数）等。

接下来LinkCode需要根据调用者所处的不同环境（虚拟机解释器环境，本地代码执行环境等）来做差异处理，为EntryPoint赋予正确的值。

我们回到ClassLinker::LinkCode 函数中继续分析。剩下还有下列几种可能性需要考虑：

- 静态非构造函数

静态非构造类型的函数比较特殊，需要另行处理。因为静态函数是不需要实例化对象的，所以可能会出现它的调用时间早于类初始化时间的情况。为了防止错误的发生，Art虚拟机设计了名为“Quick Resolution Trampoline”的Stub。它的工作原理简单来讲就是延迟确认静态函数的Entry Points，具体是在ClassLinker::InitializeClass中，即Class初始化时通过FixupStaticTrampolines来重新调整静态函数的入口地址。而此时SetEntryPointFromQuickCompiledCode中暂时设置的是GetQuickResolutionStub。

- Native函数并且Quick Code 不存在

此时设置的入口是GetQuickGenericJniStub。

- 需要解释执行的情况

此时设置的入口是GetQuickToInterpreterBridge。

- 其他

除此之外就可以保持LinkMethod中的设置，即函数的Compiled Native Code。

顺便提一下，虚拟机中有一些约定俗成的关于“跳转”的术语，例如Stub、Trampoline、Ricochet等。Stub是一种“桩”，顾名思义它们并非真正的实现体，而是为了某些“意图”而设计的中间过程。Trampoline属于Stub的一种，而且有趣的是这个词的原意是“蹦床、弹床”，这和某些场合下需要从Caller途经Stub，再“跳”到Callee的设计理念是相当吻合的。

LinkCode函数的最后，还有一段代码是针对JNI的处理，其中的核心是调用UnregisterNative。这个函数会把Jni Entry Point设置为GetJniDlsymLookupStub，即通过Dlsym这种标准的方式来完成查找动作。

接下来我们选取GetQuickToInterpreterBridge来做详细分析，以加深大家的理解。它的返回结果是一个名

为“art_quick_to_interpreter_bridge”的汇编函数——后者的职责是帮助处于Quick Code环境中的Caller函数能够正确调用需要解释器执行的Callee函数，如下所示：

```
    .extern artQuickToInterpreterBridge
ENTRY art_quick_to_interpreter_bridge
    SETUP_REFS_AND_ARGS_CALLEE_SAVE_FRAME r1, r2
    mov    r1, r9              @ pass Thread::Current
    mov    r2, sp              @ pass SP
    blx    artQuickToInterpreterBridge    @ (Method* method, Thre
    ldr    r2, [r9, #THREAD_EXCEPTION_OFFSET]  @ load Thread::Cur
    // Tear down the callee-save frame. Skip arg registers.
    add    sp, #(FRAME_SIZE_REFS_AND_ARGS_CALLEE_SAVE - FRAME_SIZ
    .cfi_adjust_cfa_offset -(FRAME_SIZE_REFS_AND_ARGS_CALLEE_SAVE
    RESTORE_REFS_ONLY_CALLEE_SAVE_FRAME
    cbnz   r2, 1f               @ success if no exception is pend
    vmov   d0, r0, r1           @ store into fpr, for when it's a
    bx     lr                   @ return on success
1:
    DELIVER_PENDING_EXCEPTION
END art_quick_to_interpreter_bridge
```

我们在分析art_quick_to_interpreter_bridge之前首先需要清楚它的调用者都有哪些，这样有助于理顺上下文环境。从前面LinkCode中的解析，我们知道art_quick_to_interpreter_bridge是作为一个bridge被设置成Quick EntryPoint的。这个入口真正派上用场的一个地方，在于ArtMethod的inovke函数。具体的函数调用流程是：ArtMethod::invoke->art_quick_invoke_stub/art_quick_invoke_static_stub->quick_invoke_reg_setup-> art_quick_invoke_stub_internal——最后的art_quick_invoke_stub_internal属于汇编函数，在它内部会进一步调用LinkCode中设置的入口，相应语句如下：

```
ldr    ip, [r0, #Art_METHOD_QUICK_CODE_OFFSET_32]
```

根据ldr的语法规则，在上述语句之前的寄存器配置操作就直接决定了art_quick_to_interpreter_bridge这个函数的可用参数了，整理如下：

r0=method pointer

r1-r3=core registers

r9 = (managed) thread pointer

不过在最终调用artQuickToInterpreterBridge之前，各寄存器值其实又做了一些调整，即：

r0=method pointer

r1=Thread::Current

r3=SP

这和artQuickToInterpreterBridge这个C函数的原型是匹配的：

uint64_t artQuickToInterpreterBridge(ArtMethod* method, Thread* self, ArtMethod** sp)

其中method代表被调用的函数(callee)，self表示当前线程，sp是一个指向代表caller的ArtMethod指针变量的指针（因为sp实际上是一个栈，它的栈顶位置保存的是ArtMethod*)。

函数artQuickToInterpreterBridge的关键点有两个：其一是为Interpreter的运行提供栈帧，即ShadowFrame。ShadowFrame有点类似于Java标准虚拟机中的Stack Frame，它用于存储方法中的本地变量表、操作栈、方法出口等信息。当然，Android虚拟机是基于寄存器来实现的，而标准Java虚拟机则基于栈来实现，所以它们两者在栈帧的具体结构上有一定差别。

ShadowFrame是由artQuickToInterpreterBridge通过如下语句创建的：

ShadowFrame* shadow_frame(ShadowFrame::Create(num_regs, nullptr, method, 0, memory));

Create函数会根据memory大小生成一个栈帧：

```
static ShadowFrame* Create(uint32_t num_vregs, ShadowFrame* lin
                           ArtMethod* method, uint32_t dex_pc, void
  ShadowFrame* sf = new (memory) ShadowFrame(num_vregs, link, m
  return sf;
}
```

num_regs:目标函数所需要的寄存器数量。Android程序在被编译成Dex前，会为每个函数提供一个名为registers_size_的变量，记录了为保证本函数正常运行所需的寄存器数量，以便虚拟机在运行态时可以正确分配资源。

method：代表目标函数的ArtMethod*。

memory：上述寄存器所占用的内存空间。

ShadowFrame同时还提供了不少操作这些寄存器的方法，如GetVReg、SetVReg 、GetVReg FromQuickCode等。Interpreter在工作过程中，需要通过ShadowFrame来完成字节码的解析和执行。

函数artQuickToInterpreterBridge的另外一个关键点是调用Interpreter提供的EnterInterpreter FromEntryPoint来真正切入到解释器中。因为栈帧已经创建，因而EnterInterpreterFromEntryPoint主要做的是一些合法性检验工作——如果一切正常的话，就可以调用Execute来真正地解析和运行字节码了。最终的执行结果将通过r0返回给调用方，然后再层层回传。

这样一来interpreter的执行就与ArtMethod的实际情况完美地结合起来，保证了interpreter中本地代码执行和字节码解释执行两种状态之间的正确切换。

- （2）本地代码的执行

本地代码的执行也会遇到和interpreter中类似的问题，即如何处理不同函数间的跳转关系——这其中的关键就在于本地代码如何与类加载系统建立无缝连接。本地代码为了解决这个难题所使用的“银弹”是Jump Table。

这同时也是AOSP工程中/art/runtime/entrypoints文件夹下数十个源文件所要完成的工作。EntryPoint的主体有3个，即Interpreter(Android N版本中的实现发生了变化，不再独立保留Interpreter EntryPoint）、Quick（早期虚拟机版本中除了Quick外还有Portable实现，不过目前也已经被移除了），以及JNI。它们在entrypoints目录下都有对应的子文件夹。

我们知道在早期的Art虚拟机版本中，它同时支持Portable和Quick两种机制。其中Portable实现外部函数引用的做法和前面小节介绍的ELF规范中的动态链接方式是非常类似的，这或许也是它“Portable”名称的由来。Quick机制则“另辟蹊径”，它并不需要像ELF那样去执行动态链接的过程，而是通过几个EntryPoint就可以完成对外部函数的调用过程。

EntryPoints是由Thread的几个全局变量管理的，如下所示：

```
/*art/runtime/Thread.h*/
class Thread {…
    JniEntryPoints jni_entrypoints;
    QuickEntryPoints quick_entrypoints;
```

它们会在Thread::Init中通过InitTlsEntryPoints来得到初始化：

```
/*art/runtime/Thread.cc*/
void Thread::InitTlsEntryPoints() {…
  InitEntryPoints(&tlsPtr_.jni_entrypoints, &tlsPtr_.quick_entryp
}
```

InitEntryPoints在多种主流的硬件架构上都有定义，如x86、Arm、mips（都同时支持32和64位版本）等。以Arm平台为例，其实现如下：

```
/*art/runtime/arch/arm/Entrypoints_init_arm.cc*/
void InitEntryPoints(JniEntryPoints* jpoints, QuickEntryPoints* q
  // JNI
  jpoints->pDlsymLookup = art_jni_dlsym_lookup_stub;

  // Alloc
  ResetQuickAllocEntryPoints(qpoints);

  // Cast
  qpoints->pInstanceofNonTrivial = artIsAssignableFromCode;
  qpoints->pCheckCast = art_quick_check_cast;

  // DexCache
  qpoints->pInitializeStaticStorage = art_quick_initialize_static_
  qpoints->pInitializeTypeAndVerifyAccess = art_quick_initialize_
  qpoints->pInitializeType = art_quick_initialize_type;
  qpoints->pResolveString = art_quick_resolve_string;
  …
```

```
  // JNI
  qpoints->pJniMethodStart = JniMethodStart;
  qpoints->pJniMethodStartSynchronized = JniMethodStartSynchroniz
  qpoints->pJniMethodEnd = JniMethodEnd;
  qpoints->pJniMethodEndSynchronized = JniMethodEndSynchronized;
  qpoints->pJniMethodEndWithReference = JniMethodEndWithReference
  qpoints->pJniMethodEndWithReferenceSynchronized =
                              JniMethodEndWithReferenceSynchroniz
  qpoints->pQuickGenericJniTrampoline = art_quick_generic_jni_tra
  …
  // Invocation
  qpoints->pQuickImtConflictTrampoline = art_quick_imt_conflict_t
  qpoints->pQuickResolutionTrampoline = art_quick_resolution_tram
  qpoints->pQuickToInterpreterBridge = art_quick_to_interpreter_b
  qpoints->pInvokeDirectTrampolineWithAccessCheck =
      art_quick_invoke_direct_trampoline_with_access_check;
  qpoints->pInvokeInterfaceTrampolineWithAccessCheck =
      art_quick_invoke_interface_trampoline_with_access_check;
  qpoints->pInvokeStaticTrampolineWithAccessCheck =
      art_quick_invoke_static_trampoline_with_access_check;
  qpoints->pInvokeSuperTrampolineWithAccessCheck =
      art_quick_invoke_super_trampoline_with_access_check;
  qpoints->pInvokeVirtualTrampolineWithAccessCheck =
      art_quick_invoke_virtual_trampoline_with_access_check;

  // Thread
  qpoints->pTestSuspend = art_quick_test_suspend;
…}
```

变量jpoints和qpoints分别对应JNI和Quick两个主体。它们的数据结构各不相同，例如JniEntryPoints的实现如下：

```
struct PACKED(4) JniEntryPoints {
  // Called when the JNI method isn't registered.
  void* (*pDlsymLookup)(JNIEnv* env, jobject);
};
```

JniEntryPoints结构体中只有pDlsymLookup一个函数指针，只有当JNI Method没有注册的情况下它才会被调用。

QuickEntryPoints可以说是最重要的一个EntryPoint，因为Art中的一大特性就是将Dex转成了Oat ——这是虚拟机运行速率得以提升的一大根因。可以看到，QuickEntryPoints包含的内容很多，从Alloc、Cast、DexCache、Field访问控制、Math计算等都有涉及。这样一来Oat中的本地代码在需要访问上述分类中的函数时，就完全可以通过这些

entrypoints入口地址来获取了。由于这种访问是不涉及动态链接过程的，所以理论上讲会比传统方式来得快（这是其被命名为“Quick”的最主要原因）。

Thread中提供的上述这些入口函数如何可以让Oat中的本地代码方便地访问到呢？这就是Android虚拟机的调用约定中将寄存器r9用于保存Current Thread的用意所在了，我们在后续小节中还有更详细的分析。

只要dex2oat编译生成的native code遵循r9寄存器的约定，那么本地代码就可以在必要的时候通过这个寄存器找到上述的Jump Table(Entry Points)，进而重新回到Runtime环境中，然后借助于类加载系统来找到和调用目标函数，从而实现本地代码对外部函数的引用。这样一来无论是解释器还是本地代码，它们都可以做到“互联互通”了。

21.9　Art虚拟机的“中枢系统”——执行引擎之Interpreter

接下来的章节内容中我们将逐一揭开Android虚拟机执行程序的3种主要方式，分别是Interpretation、JIT和AOT。

我们知道在Android Dalvik时代，解释器其实是有C可移植版本和汇编代码两个版本的。但是Android Art在取代Dalvik的早期，却只提供了C语言实现的Interpreter。猜测这很可能是因为当时Art虚拟机中引入的AOT实现大幅提升了虚拟机性能，它的作者们认为Interpreter已经处于相对“弱势”的地位，甚至是可有可无的（除了某些特殊情况）状态，所以也就没有特意去关心解释器的效率问题了。但是到了Android N版本时这种情况又发生了变化。简单来说，Art虚拟机是一个Interpreter+JIT+AOT大融合的环境，这3种执行方式各有优缺点，并不存在非此即彼的关系。因而为了达到它们三方之间的一种最佳平衡，Android虚拟机团队不得不重新选择在Interpretation上加大功夫，于是又出现了汇编版本的解释器。具体原因和细节我们在下一小节讲解JIT时还会有阐述。

本小节我们着重来分析Android N版本中解释器的内部实现原理。

Interpreter对应的源码路径是art/runtime/interpreter，除了不多的几个C++源文件外，其他与平台相关的汇编代码则保存在子目录mterp里。

和所有标准JVM虚拟机中解释器所担负的职责类似，Android系统给解释器分配的任务也是解析字节码并予以执行。解释器的抽象模型可以表示如图21-57所示。

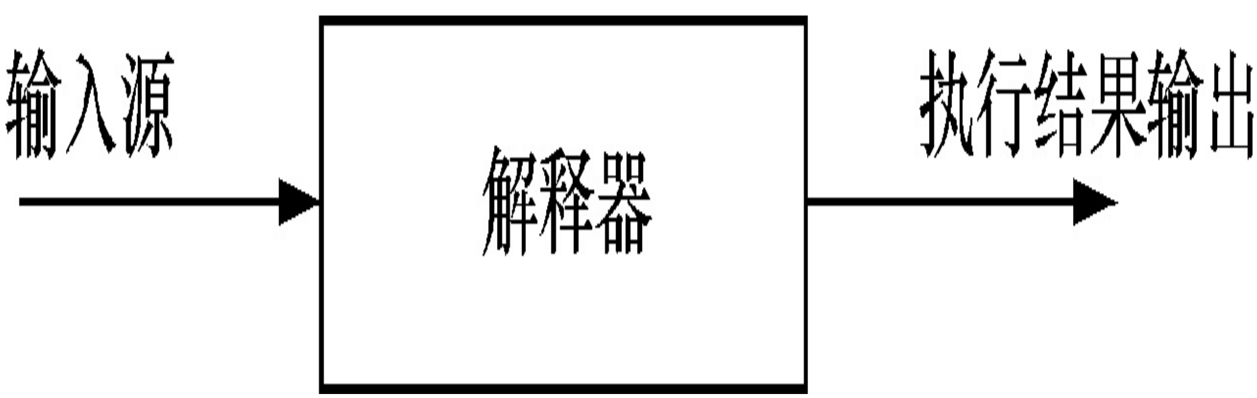

▲图21-57 模型

输入源既可以是最原始的编程语言，也可以是类似于Java中的Bytecode的这类中间表示。从这个角度来看它和编译器的区别在于：前者是对程序语义的执行结果，而编译器则是用另一种语言来表示原始语言（通常原始语言比编译器输出语言高级，例如从C语言编译成机器语言）。解释型语言并不代表完全不需要编译，事实上很多解释器的内部实现也是先编译源码，然后才加以执行。只不过对于用户来说编译的过程是透明未可知的，从而让人产生了“解释执行的错觉”。从编程语言的角度而言解释器并没有被规定具体的实现方式，所以我们说解释型语言或者编译型语言，在定义上都应该加上限定词——即它们的“主要/主流”的实现方式是解释执行或者编译执行，这样才不至于引起误解。

对于Android虚拟机中的解释器，输入源特指的是Android字节码。大家可以先思考一下对于这种线性的字节码序列，解释器应该如何执行它们呢？

首先可以想到的是用一个switch语句来分别处理每一条字节码，类似下面这样的代码结构：

```
while(NOT_END){
     switch(opcode){
          case CODE_1:
               do_something;
               break;
          case CODE_2:
               do_something;
               break;
          …
     }
     取新的指令;
)
```

这事实上就是Java虚拟机经典的switch型解释器的锥形。它的内部结构虽然相当清晰简洁，但是却存在一个致命的问题——效率低下。这其中的“罪魁祸首”是每条指令的执行都需要“漫长”的判断过程——即从CODE_1开始，直到匹配到正确的目标指令，如此循环往复。这样一来当指令数量达到一定规模时，这种结构的弊端就非常明显了。

Android N版本也提供了switch类型的解释器，其入口函数是ExecuteSwitchImpl，核心代码如下所示：

```
/*art/runtime/interpreter/interpreter_switch_impl.cc*/
template<bool do_access_check, bool transaction_active>
JValue ExecuteSwitchImpl(Thread* self, const DexFile::CodeItem* c
                         ShadowFrame& shadow_frame, JValue result
                         bool interpret_one_instruction) { …
  do {
    dex_pc = inst->GetDexPc(insns);
    shadow_frame.SetDexPC(dex_pc);
    TraceExecution(shadow_frame, inst, dex_pc);
    inst_data = inst->Fetch16(0);
    switch (inst->Opcode(inst_data)) {
      case Instruction::NOP:
        PREAMBLE();
        inst = inst->Next_1xx();
        break;
      case Instruction::MOVE:
        PREAMBLE();
        shadow_frame.SetVReg(inst->VRegA_12x(inst_data),
                             shadow_frame.GetVReg(inst->VRegB_12x
        inst = inst->Next_1xx();
        break;
…
    }
  } while (!interpret_one_instruction);
```

从这个函数可以看出Android中的switch型虚拟机符合我们前述的经典结构。

既然switch类型的虚拟机效率上存在重大缺陷，那么我们是否有什么改进方法呢？

相信大家会很自然地想到Goto方式。没错，Switch结构最大的问题在于需要逐一去寻找“每一条指令所对应的处理函数”，那么如果我们将指令与其处理函数直接建立“一对一”的联系，性能问题理论上就迎刃而解了。可以参考Android里的具体实现，在interpreter_goto_table_impl.cc的ExecuteGotoImpl函数中：

```
template<bool do_access_check, bool transaction_active>
JValue ExecuteGotoImpl(Thread* self, const DexFile::CodeItem* cod
shadow_frame, JValue result_register) {
                      static const void* const
                 handlersTable[instrumentation::kNumHandlerTables
    {
    // Main handler table.
#define INSTRUCTION_HANDLER(o, code, n, f, r, i, a, v) &&op_##cod
```

```
#include "dex_instruction_list.h"
      DEX_INSTRUCTION_LIST(INSTRUCTION_HANDLER)
#undef DEX_INSTRUCTION_LIST
#undef INSTRUCTION_HANDLER
    }, {
    // Alternative handler table.
#define INSTRUCTION_HANDLER(o, code, n, f, r, i, a, v) &&alt_op_#
#include "dex_instruction_list.h"
      DEX_INSTRUCTION_LIST(INSTRUCTION_HANDLER)
#undef DEX_INSTRUCTION_LIST
#undef INSTRUCTION_HANDLER
    }
  };
…
```

根据Goto结构的设计思路，我们首先需要构造一个数组。不难看出上述代码段中的handlersTable是一个二维数组，包含了“Main”和“Alternative”两种Handler Table。其中Main Table是正常情况下的指令处理函数的集合，Alternative Table则主要在Instrumentation（Android虚拟机提供的一种插桩机制，以保证单步调试、Tracer等可以正常工作）的情况下发挥作用：

```
 …
HANDLE_INSTRUCTION_START(MOVE)
    shadow_frame.SetVReg(inst->VRegA_12x(inst_data),
                         shadow_frame.GetVReg(inst->VRegB_12x(ins
    ADVANCE(1);
  HANDLE_INSTRUCTION_END();

  HANDLE_INSTRUCTION_START(MOVE_FROM16)
    shadow_frame.SetVReg(inst->VRegA_22x(inst_data),
                         shadow_frame.GetVReg(inst->VRegB_22x()))
    ADVANCE(2);
  HANDLE_INSTRUCTION_END();
  …
```

上述代码段中的HANDLE_INSTRUCTION_START用于定义一个opcode的label，如下所示：

```
#define HANDLE_INSTRUCTION_START(opcode) op_##opcode:
```

前面在定义handlersTable时，每一项的取值都是&&op_##code，这样一来opcode就和它对应的处理代码建立起关联了。

另外，ADVANCE宏用于取出并跳转到下一个指令去执行，从而保证程序的正常运行；HANDLE_INSTRUCTION_END的主要用途是“分隔”各个指令——因为ADVANCE会跳转到其他指令去执行，所以任何情况下程序如果走到HANDLE_INSTRUCTION_END的话就说明出现了严重的问题，此时会导致程序的崩溃。

最后我们再来讨论一下汇编语言实现的解释器。

需要强调的是，基于汇编的解释器并不是Android N版本或者Art虚拟机独创的，因为早在Dalvik时代Android就提供了portable和fast两种版本的解释器了，它们分别是由C和汇编语言编写完成的。所以这次Android N版本中引入汇编解释器只能说是它“重返疆场”。

汇编解释器虽然执行效率高，但缺点也是明显的——它需要针对不同的硬件架构进行适配。目前Android N版本中已经支持arm、arm64、mips、mips64、x86和x86_64等多种硬件体系，它们都统一被放置在art/runtime/interpreter/mterp目录下。每一个opcode的处理代码都以一个单独的.S文件来提供，例如op_aget.S、op_aget_char.S、op_aput.S等。

至于具体是采用switch、Goto抑或是Assemble解释器，首先是由kInterpreterImplKind变量决定的——它的初始值是kMterpImplKind，即汇编解释器。然后我们还需要根据运行过程中的实际情况来做调整。某些情况下汇编解释器是无法满足程序的运行需求的，例如它并不能有效支撑所有的instrumentation和debugging的场景。此时我们就要选择切换到switch或者Goto类型来保证程序的正常运行。

21.10 Art虚拟机的“中枢系统”——执行引擎之JIT

和AOT相反，Just-in-time compilation是一种动态编译，意味着它是在程序运行过程中才执行的编译工作。JIT在Android虚拟机中的应用历史是比较有戏剧性的，具体描述如下所示：

Android Dalvik时代：JIT是虚拟机中保证运行效率的重要保障机制。

Android ART（N版本之前）：JIT“退隐江湖”。

Android ART（N版本开始）：JIT又“重出江湖”。

21.10.1 JIT重出江湖的契机

除了技术方面的考虑外，有的时候“政治”原因事实上更有权利决定一项技术的“生死”，这一点无论在大公司还是小公司都是一样的。当然，这类因素并不属于本书所要考虑的范围，我们还是专注在技术领域的分析吧。

在本章的开头，我们已经对Art与Dalvik做了性能对比，可以看出前者确实是存在优势的。支撑Art的核心技术是AOT，它和JIT从理论上讲是两个概念。不过这并不能说明JIT就一无是处。相反，它们各有优缺点——譬如JIT显然比AOT更节省存储空间；而且不需要在程序安装，或者每次系统升级/应用程序升级后都做AOT优化。图21-58所示是我们在Android N版本之前会经常看到的一个用户界面。

▲图21-58 用户界面

由于Google安全补丁更新越来越频繁，这就意味着用户很可能会在一个月甚至更短的时间内经历图21-58所示的优化过程。从而给Android

的用户体验带来新的挑战。

那么我们是否有可能将它们做一个融合，取各家所长，补双方所短呢？

这或许是Android N中引入JIT的一个重要原因，我们可以从Google I/O 2016会议上提供的材料得到一些启发，如图21-59所示。

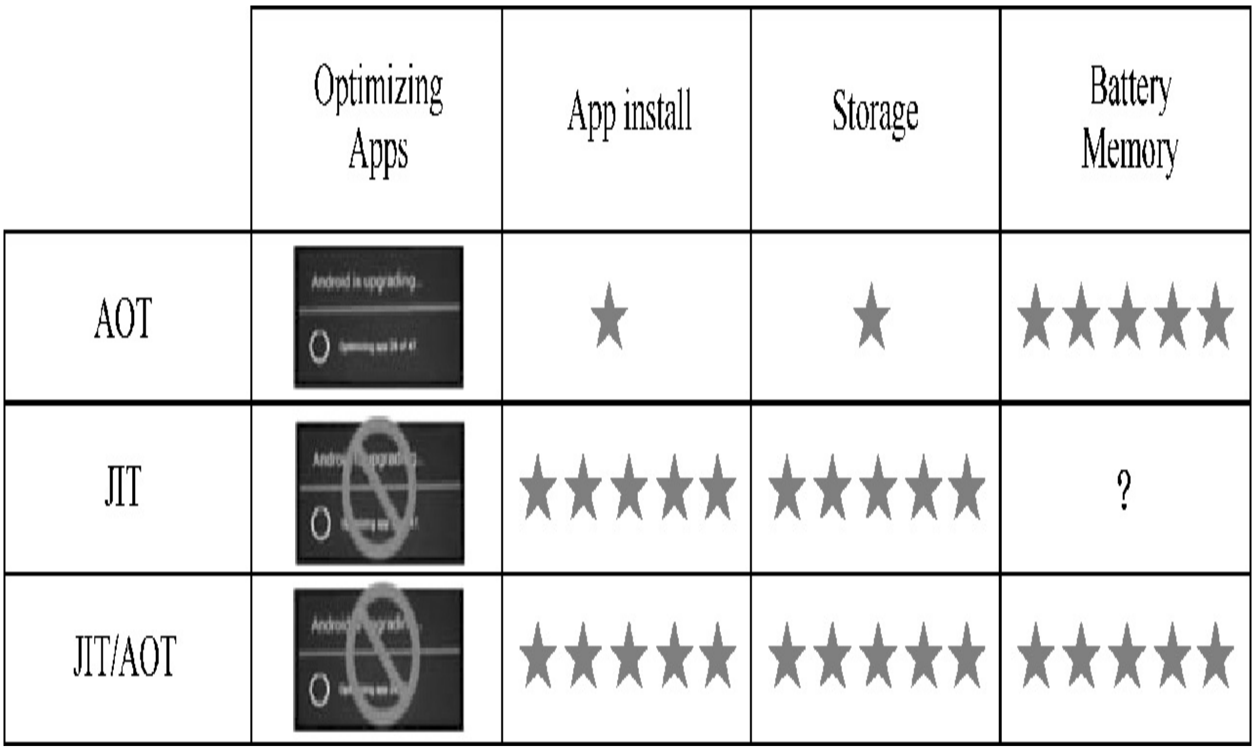

▲图21-59　Android N版本中重新引入JIT技术的潜在优势{-:-}（引自Google I/O 2016）

可以看到JIT和AOT的结合在Android虚拟机的多个方面上都带来了可喜的提升，接下来的几个小节中我们将逐一揭晓隐藏在这些新变化之后的实现原理。

21.10.2　Android N版本中JIT的设计目标及策略

JIT在设计初期主要设定了如表21-11几个目标，并提出了相应的设计策略：

表21-11　目标及策略

考量因素	设计策略
保证程序的安装速度以及更新时的处理速度	因为不需要在程序安装时执行AOT预编译，所以不会出现漫长的安装等待
保证程序的启动速度	Android N版本中的JIT至少采用了如下几种方式来保证程序的启动速度：（1）足够快的解释器，可以参考前一小节的分析（2）调整Dex的verification时机，见下面的详细说明（3）在运行过程中记录影响启动速度的Classes，并做特别优化（4）为应用程序提供Image。在之前的版本中，只有boot.art具有这种特性，而Android N版本将这种优势扩大到了所有的应用程序中
避免JIT导致程序卡顿	JIT的编译过程在独立的线程中完成，并且给UI线程更高的优先级
电池续航	只编译那些有必要的函数
内存	

使用	新的GC策略，保证无用的内存占用被及时清理

为了保证程序的启动速度，Art开发小组做了如下一系列针对Gmail的实验，如图21-60所示（图例无特别说明均引用自Google I/O 2016）。

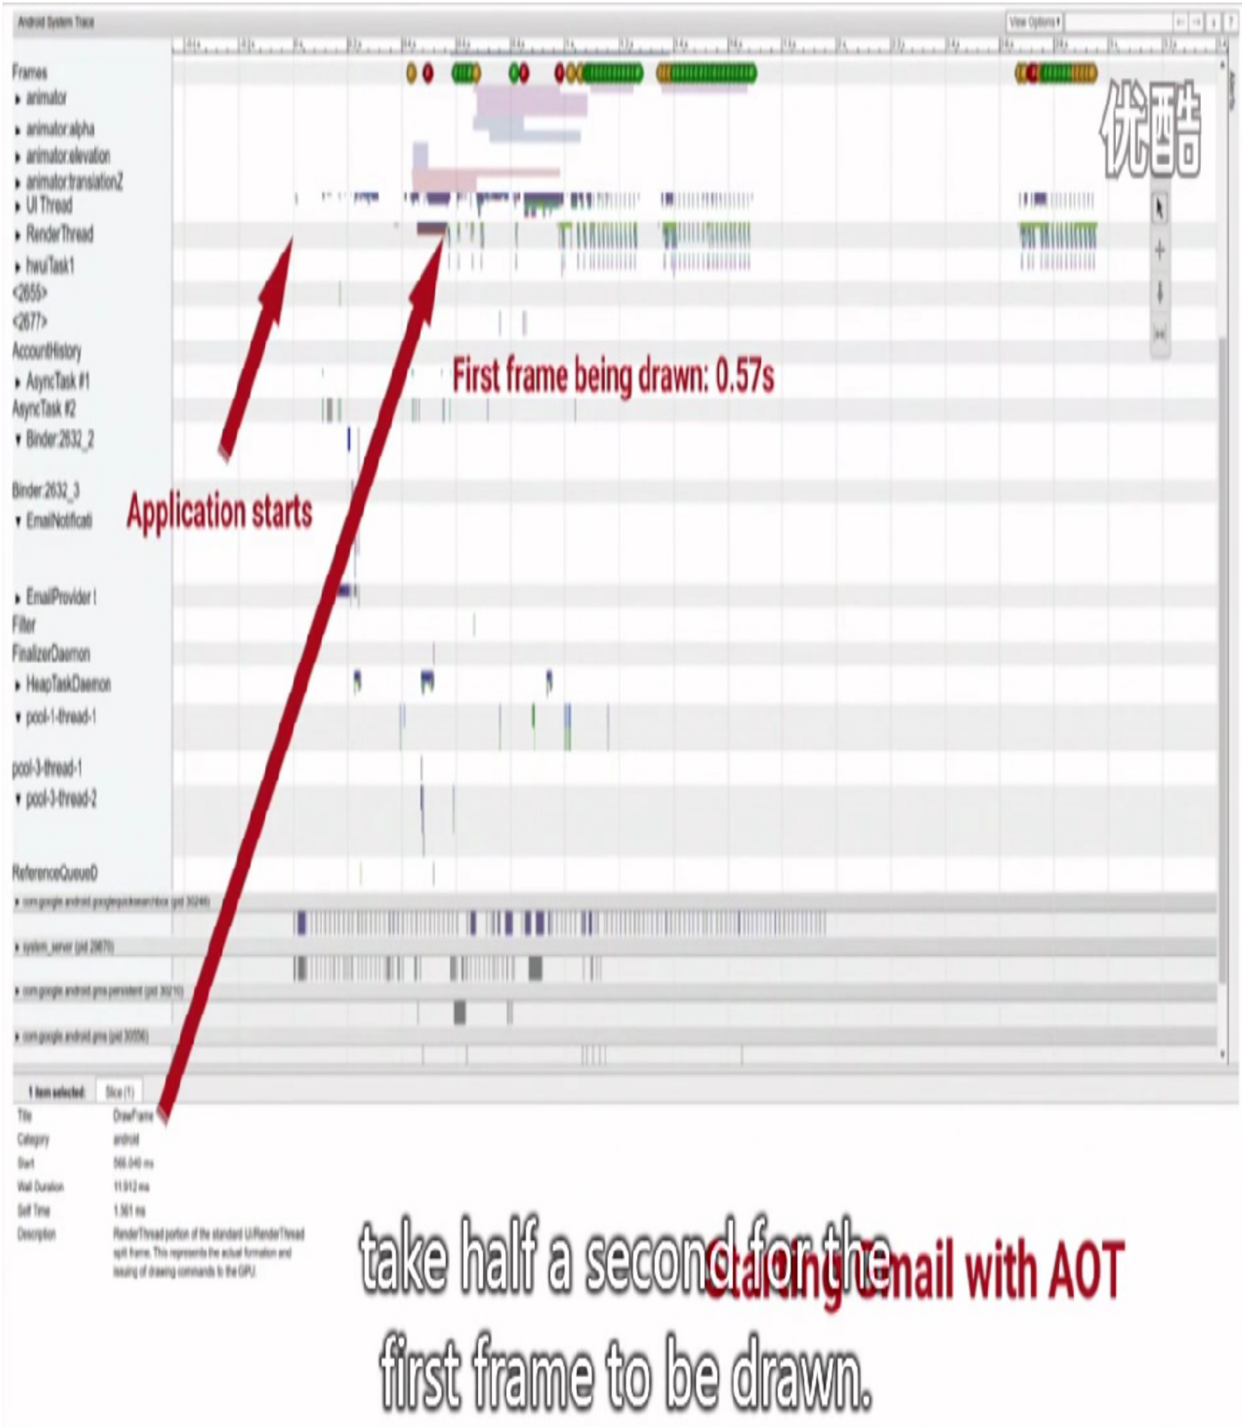

▲图21-60　Android M版本上Gmail的启动耗时数据

（1）首先在Android MashMallow上启动Gmail，并利用SysTrace抓取到如图21-60所示的数据。

可以看到在Android M版本上Gmail启动第一帧所需时间为0.57秒。

（2）紧接着是在Art小组实现的第一个JIT版本上针对上述步骤中的同一个程序展开实验。

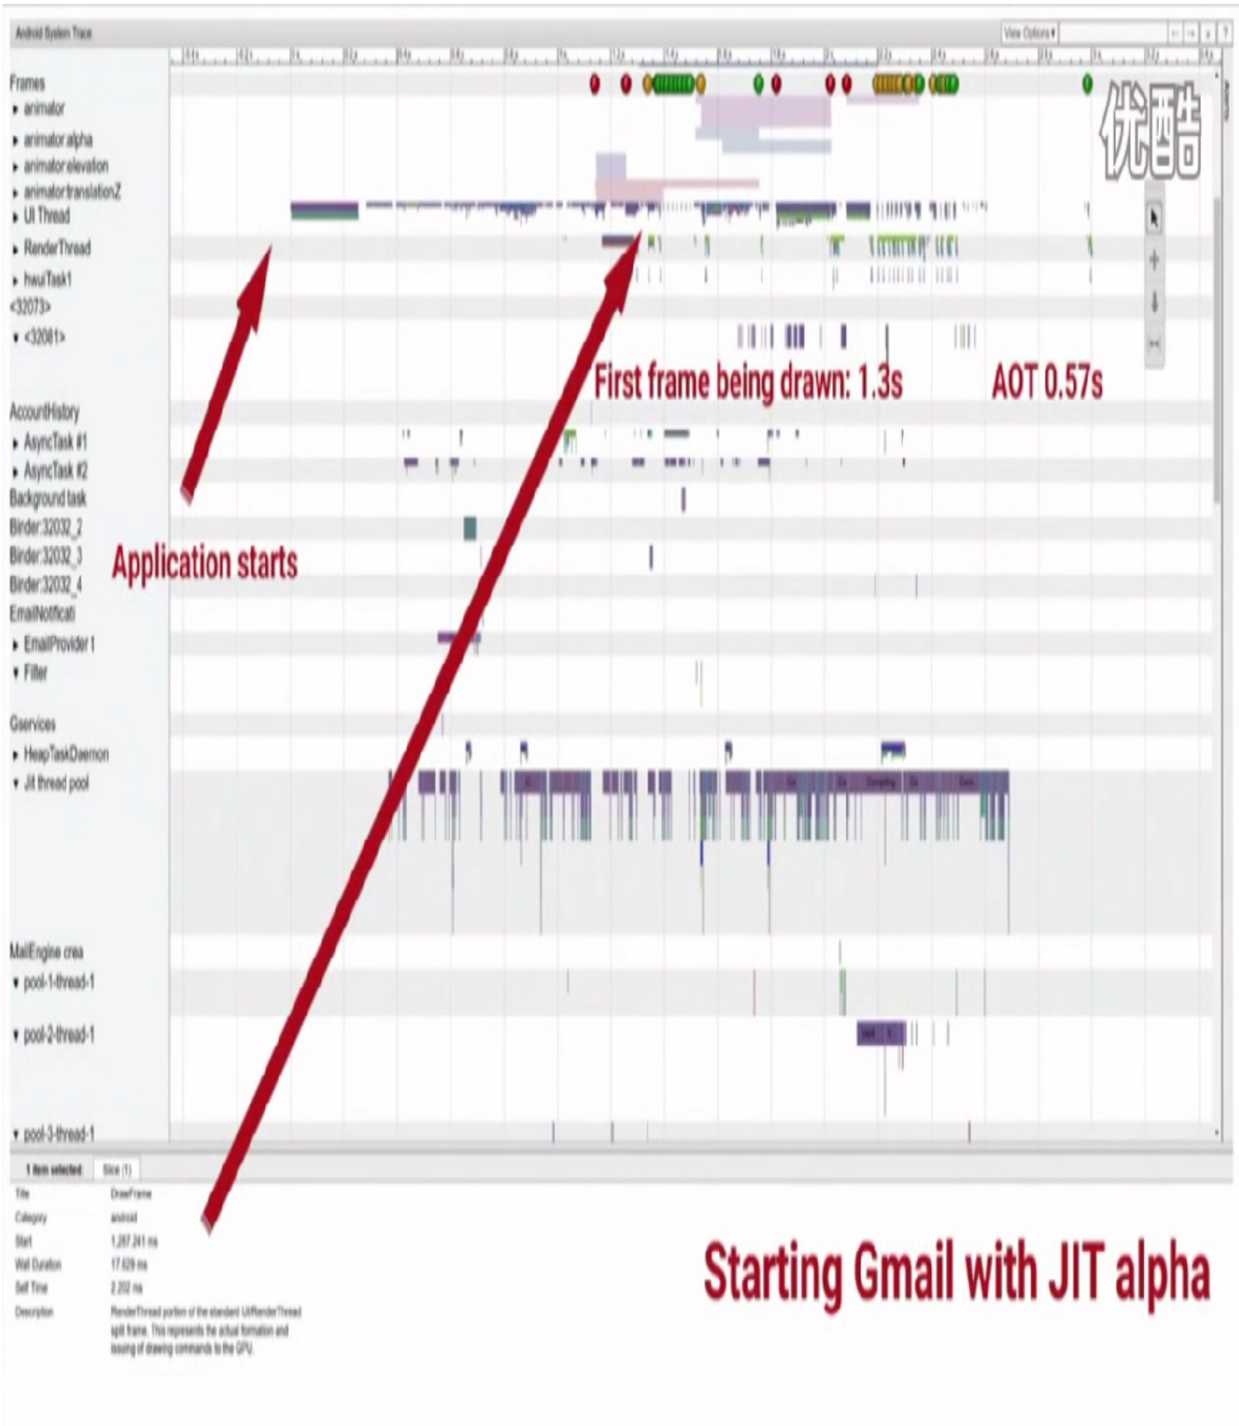

▲图21-61　Android N上第一个JIT版本启动Gmail的耗时数据

从图21-61所示可以看到这种情况下启动第一帧所需时间为1.3秒，差不多为AOT版本中的2倍。

（3）那么是什么原因导致了JIT情况下的启动速度变慢呢？如图21-62所示。

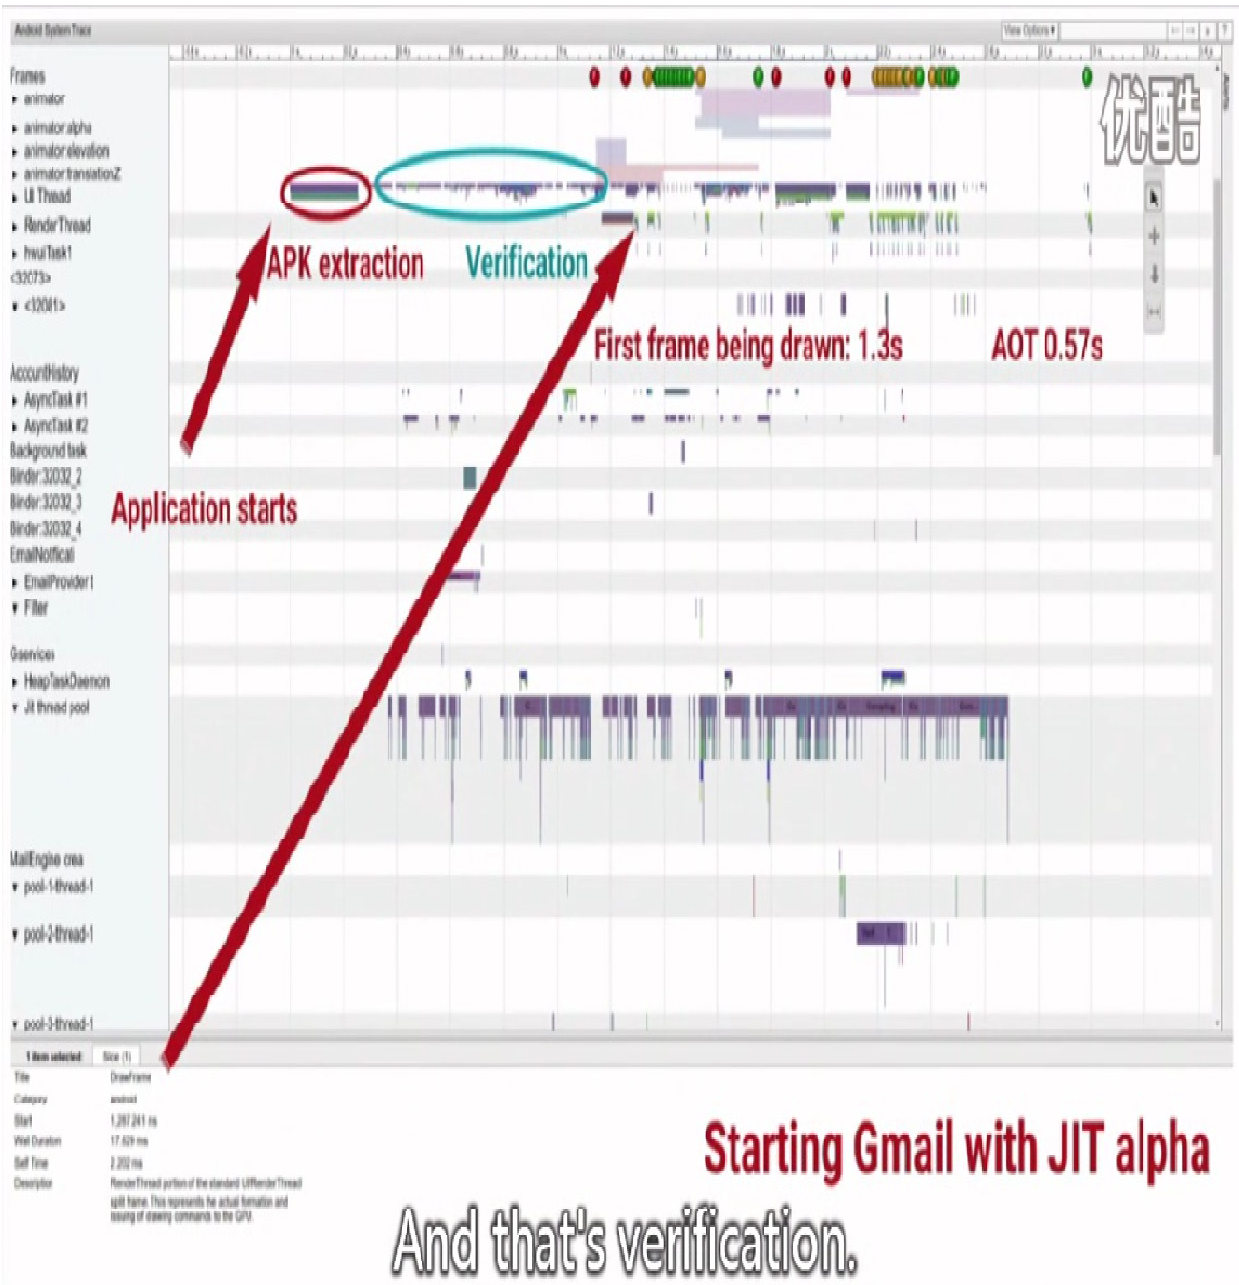

▲图21-62　启动慢的原因分析

由图21-62可以看到，在第一帧显示之前APK经历了Extraction和Verification两个阶段，它们都将在一定程度上拖慢启动速度。因而Art小组一方面尝试将这两个动作前移到程序的安装阶段，另一方面在解释器的提速上做了很多工作（包括提供汇编版本的解释器），最后让程序的启动速度有了明显改善，如图21-63所示实验结果。

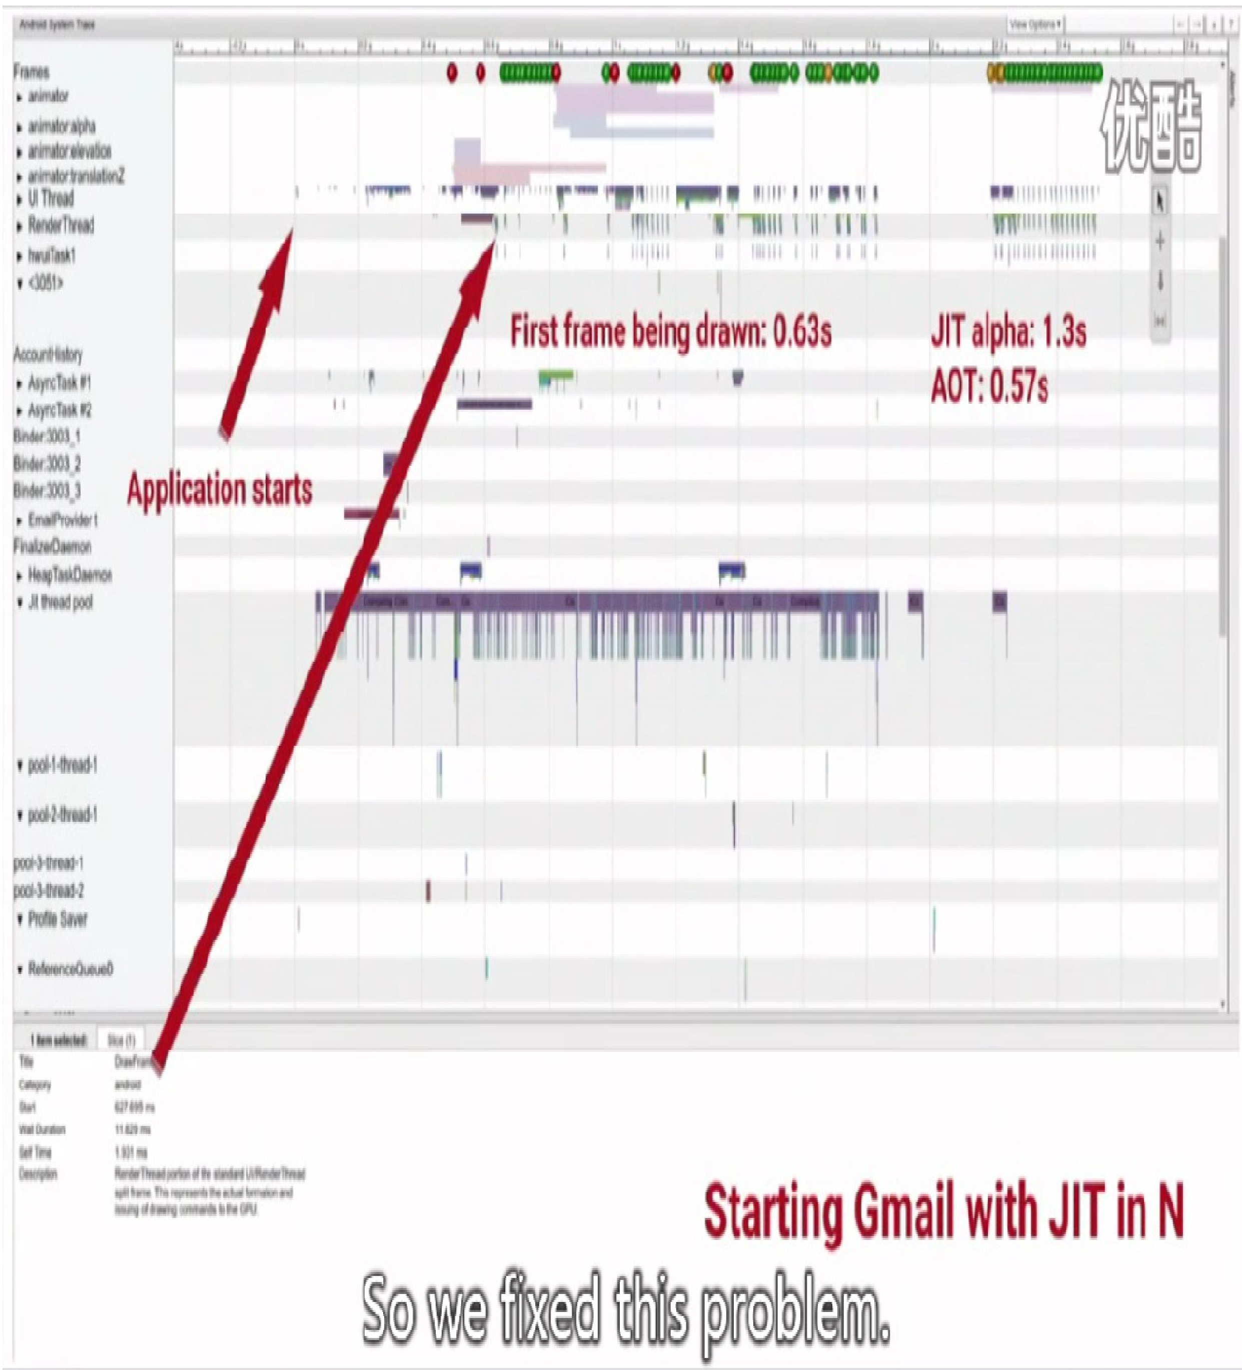

▲图21-63　经过优化后的JIT版本实验结果

采取了多种改进措施后，Gmail程序在Android N版本中的第一帧启动时间降低到了0.63秒，和AOT已经非常相近了。

21.10.3　Profile Guided Compilation（追踪技术）

从前面章节的学习中，我们知道Android M版本中的AOT编译有两个主要的执行时机，即ROM系统编译时以及第三方应用程序安装时。那么大家可以思考一下，JIT编译又该在什么时候执行才是最合适的呢？

根据JIT的设计理念，它显然不会像AOT那样对程序的大部分Java代码都进行编译（注意：理论上这是可以配置的），所以必定需要一套追踪机制来决定哪一部分代码需要被执行JIT——即“热区域”的确定。和传统的JIT不同的是，Android N版本中的追踪技术又被称为“Profile Guided Compilation”。

Profile Guided Compilation的基本工作原理如图21-64所示。

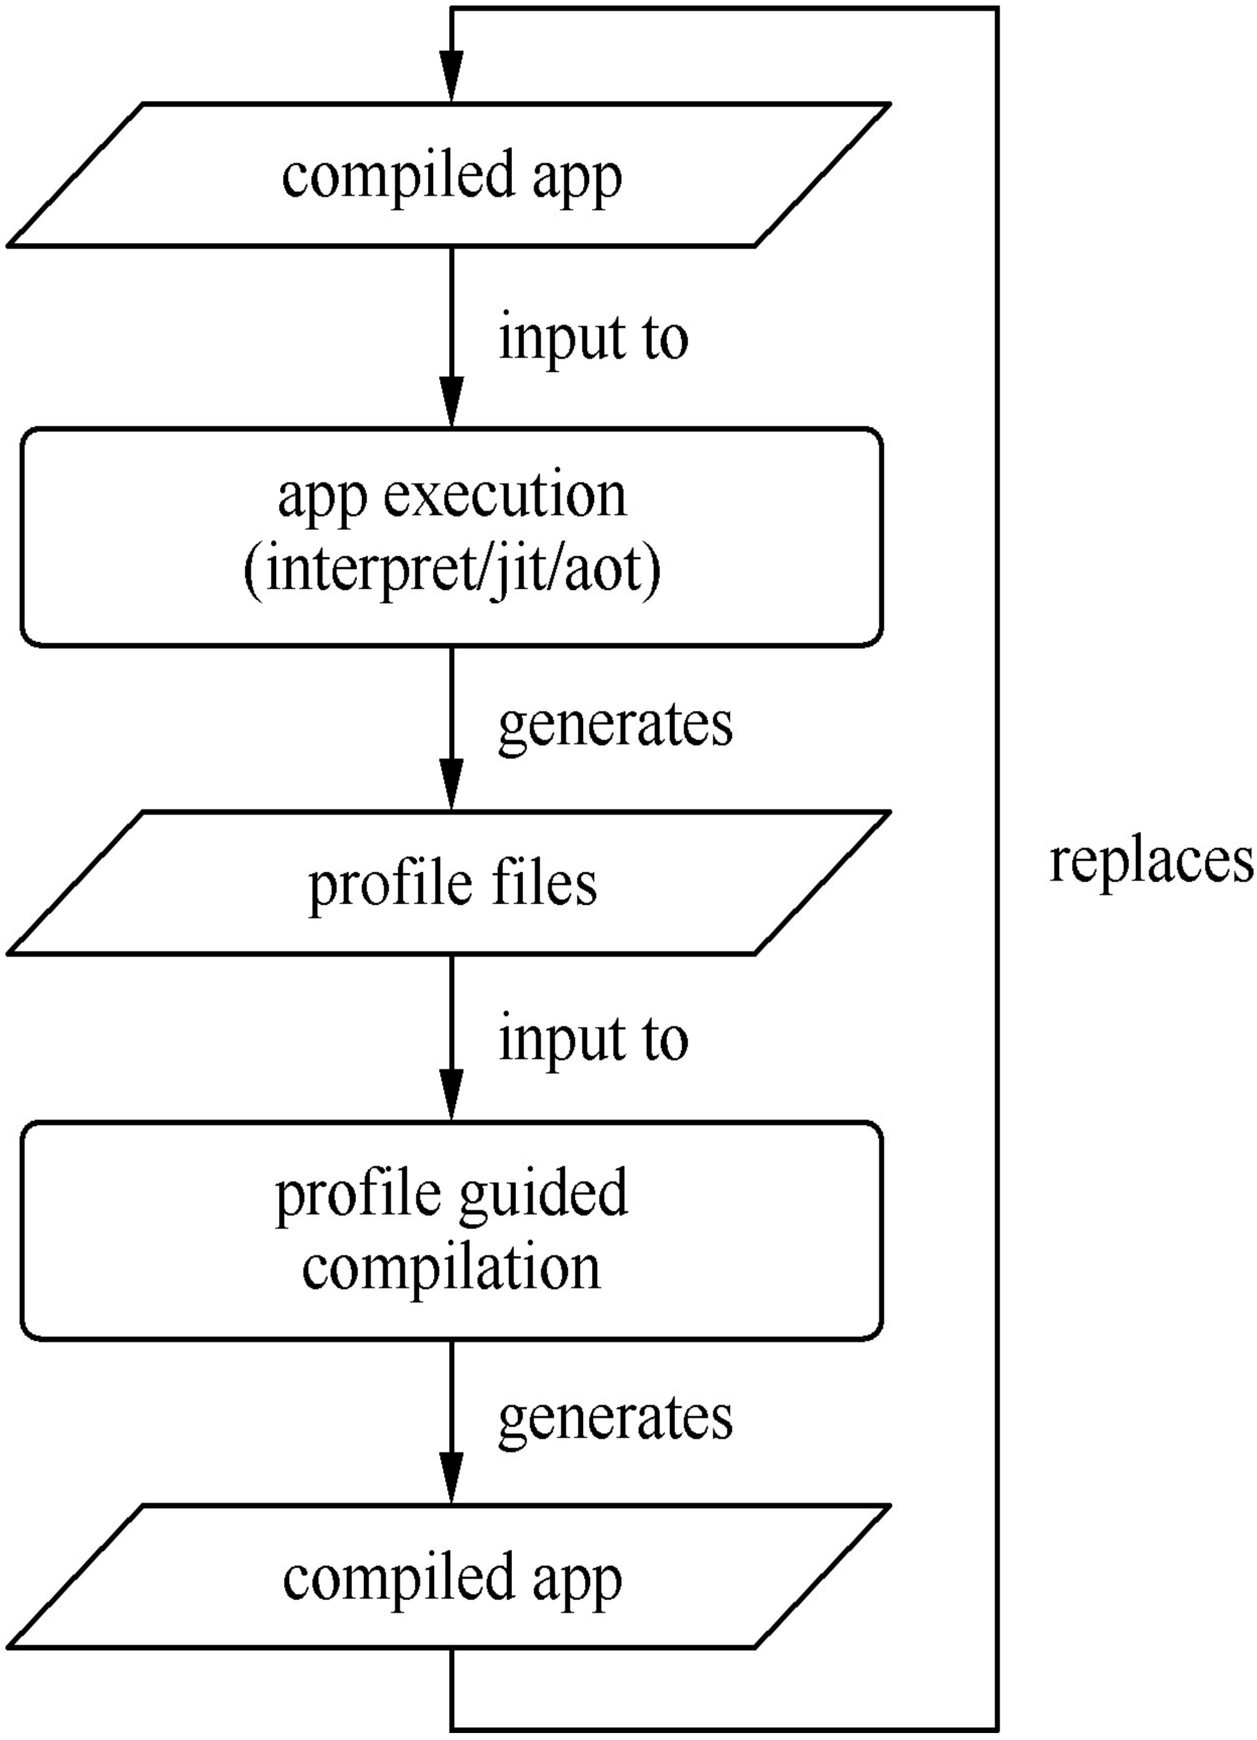
compiled app
input to
app execution
(interpret/jit/aot)
generates
profile files
input to
profile guided
compilation
generates
compiled app
replaces

▲图21-64 基本工作原理

Step1. 当应用程序第一次启动时，只会通过解释器执行，同时JIT会介入并针对hot methods执行优化工作。

Step2. 上述执行过程中还将同步输出一种被称为“Profile information”的信息，并按一定规律保存到文件中。Profile文件属于程序属主“私人”持有。

Step3. 上述两个步骤会被重复执行，因而Profile information得到不断地完善。

Step4. 当设备处于idle状态并且同时还在充电时，就进入了Profile guided compilation服务。这个编译过程将以Profile information文件为输入，最后的输出则是二进制机器代码。后者会被用于替代原始应用程序的相应部分。

那么我们需要在Profile information中记录哪些必要的数据呢？

- Hot Methods

即需要离线优化的函数。

- 影响程序启动速度的Classes

用于进一步优化程序的启动速度。

……

Step5. 在经过上述步骤后，应用程序在后续启动时就可以根据实际情况来在AOT/JIT/ Interpretion中择优选取一种执行方式了。

JIT在Android N版本中有专门的源代码目录，即AOSP/art/runtime/jit。它在Runtime::Start中会被启动，如下所示：

```
/*art/runtime/runtime.cc*/
bool Runtime::Start() {…
  if (jit_options_->UseJIT()) {
    std::string error_msg;
```

```
    if (!IsZygote()) {
      CreateJit();
    } else if (!jit::Jit::LoadCompilerLibrary(&error_msg)) {
      // Try to load compiler pre zygote to reduce PSS. b/2774494
      LOG(WARNING) << "Failed to load JIT compiler with error " <
    }
  }
```

JIT相关的选项jit_options_是在Runtime::Init中赋值的，其中是否启用JIT由下面语句判断：

```
  jit_options->use_jit_ = options.GetOrDefault(RuntimeArgumentMap
```

而RuntimeArgumentMap::UseJIT的具体值取决于系统变量“dalvik.vm.usejit”，后者将由AndroidRuntime在启动虚拟机时和其他VM选项一起处理。

毫无疑问JIT系统是一个单实例，静态函数Jit:: Create负责这一实例的生成工作。JIT的核心工作都是在自己独立的线程中完成的，以避免对程序运行性能造成影响（即Jank事件）。

根据Profile Guided Compilation的工作原理，JIT模块所要完成的主要任务如下：

- 监测程序的运行情况，获取“感兴趣”的信息

这个工作具体是由JitInstrumentationListener完成的，它和我们在本章中分析的Instrumentation是息息相关的，大家可以自行阅读代码了解详情。

- 将获取到的信息保存到文件中

具体是由ProfileSaver这个类完成的。

- 翻译热点函数

实时翻译运行过程中的热点函数的能力是由libart-compiler.so或者libartd-compiler.so提供的，具体对应的是jit_compile_method函数，并保存在JitCodeCache中。这样一来某个ArtMethod在执行时除了考虑AOT和Interpretation之外，还需要综合参考JIT保存在全局变量

code_cache_中的结果。

了解了JIT模块的职责后，读者们可能还有这样的疑问，即AOT又是在什么时候由哪个模块负责执行的呢？我们在下一小节中来回答这个问题。

21.10.4 AOT Compilation Daemon

为了满足Profile Guided Compilation（JIT）的编译特点，我们需要一个独立的Daemon来响应Offline AOT Compilation。Daemon的概念相信大家并不陌生，Android系统中拥有多个与之类似的守护程序，例如adbd、netd等。

当AOT Daemon启动后，它的核心处理逻辑如图21-65所示。

- 当设备同时处于idle和充电状态下时，Daemon被唤醒并通过遍历来分析系统中的所有应用程序，以决定是否需要执行AOT操作。
- 如果应用程序是“共享”的，那么需要对它执行完全的编译动作。
- 否则查找应用程序中是否有对应的Profile文件。如果答案是否定的话，直接放弃;反之进入真正的Profile guided compilation。

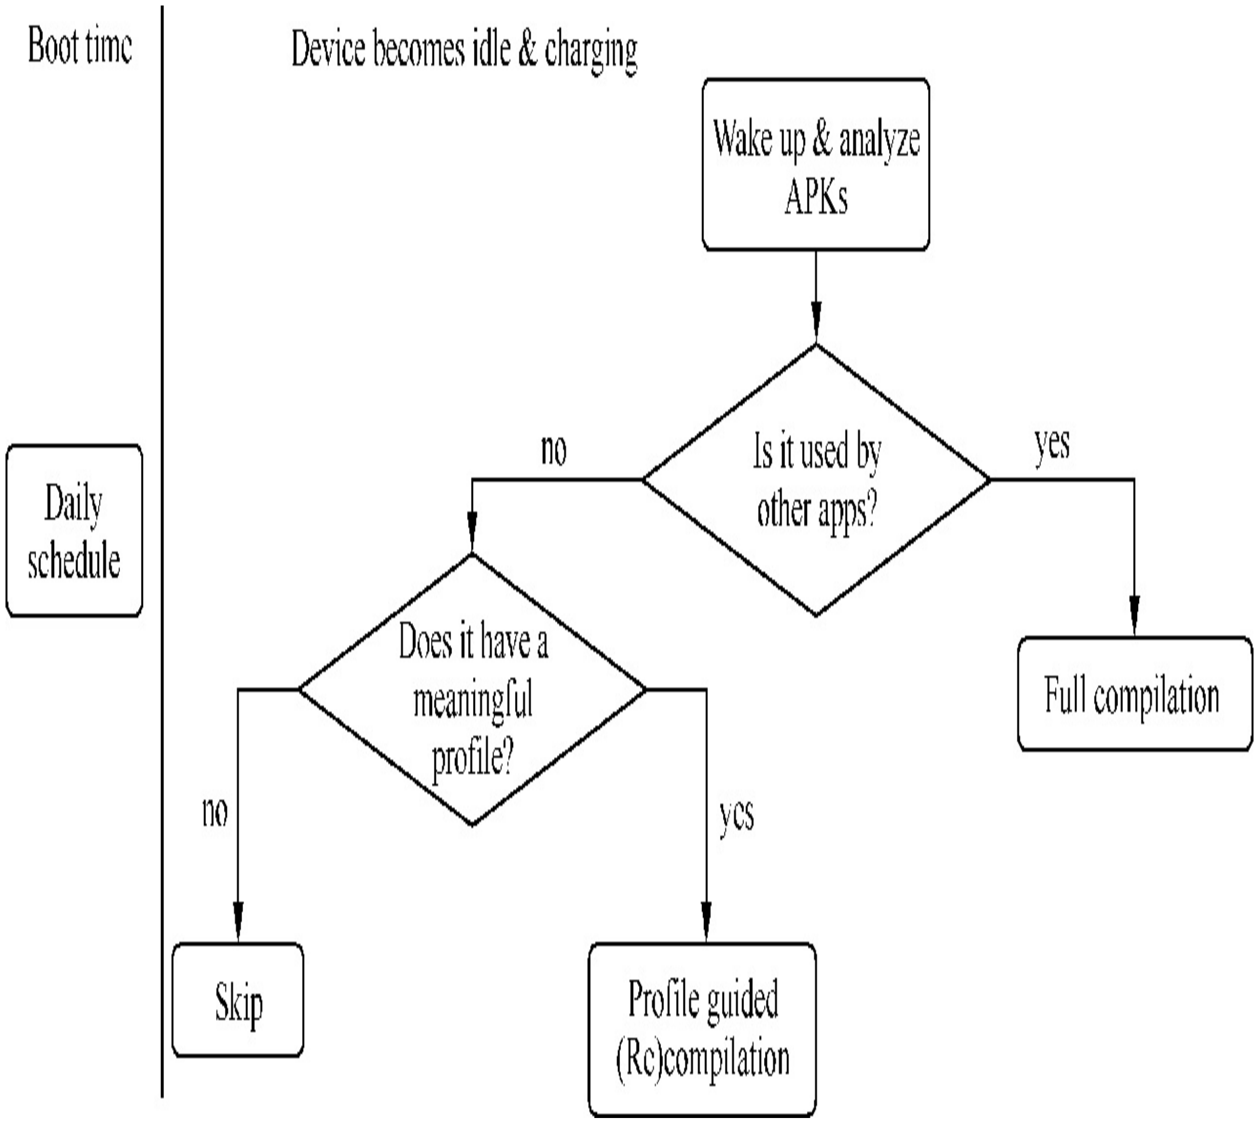

▲图21-65 AOT Daemon的核心处理逻辑

Profile guided compilation事实上也属于AOT技术的范畴，所以它完全可以在复用Android M版本dex2oat的基础上再进行部分改造。这一点我们从dex2oat.cc文件针对option的处理中亦能看出一些端倪：

```
…
else if (option.starts_with("--profile-file=")) {
        profile_file_ = option.substr(strlen("--profile-file=")).
      } else if (option.starts_with("--profile-file-fd=")) {
        ParseUintOption(option, "--profile-file-fd", &profile_fil
      } else if (option == "--host") {
```

我们通过内容小结来帮助大家将所有知识点做一个“串接”：

- 不同于Marsh Mallow中针对所有应用程序预先执行AOT的做法，Android N版本并不会在应用程序安装过程中调用dex2oat。一方面，这种新变化大幅加快了程序的安装速度，解决了系统更新时用户需要经历漫长等待的问题；另一方面，由于程序的首次启动必须通过解释器来运行，Android N版本必须采用多种手段（新的解释器、将Verification前移等）来保证程序的启动速度不受影响。
- 应用程序除了解释执行外，还会在运行过程中实时做JIT编译——不过它的结果并不会被持久化。另外，虚拟机会记录下应用程序在动态运行过程中被执行过的函数，并输出到Profile文件里。
- AOT compilation daemon将在系统同时满足idle和充电状态两个条件时才会被唤醒，并按照一定的逻辑来遍历执行应用程序的AOT优化。由于参与AOT的函数数量通常只占应用程序代码的一小部分，所以整体而言Android N版本中AOT结果所占用的空间大小比旧版本要小很多。

21.11 Art虚拟机的“中枢系统”——执行引擎之本地代码

前面几个小节我们综述了虚拟机中代码的执行过程，并且对JIT、Interpreter两种方式进行了扩展分析。现在是时候阐述虚拟机中另一个重要的执行引擎了，即本地代码的执行过程。

我们可以从以下两个角度来思考：

- Zygote

我们知道，Zygote是一切Android应用程序的“鼻祖”，而这个“孵化器”自身除了包含一小部分本地代码外，其他绝大部分也是通过Java语言实现的。这意味着它也需要启动一个虚拟机实例来执行代码程序。而Zygote本身的功能又是比较单纯的，所以它是我们分析虚拟机中代码执行过程的一个很好的介入点。

- Apk应用程序

Android虚拟机的最大价值体现在应用程序中。一旦我们掌握了Zygote中是如何利用Art虚拟机来为其服务的“脉络”以后，那么对APK应用程序部分的理解就只要侧重于和Zygote的差异部分就可以了。

大家应该注意到了，Zygote在调用AndroidRuntime的start函数时传入了一个Class名称，如下所示：

```
runtime.start("com.android.internal.os.ZygoteInit", args);
```

这个ClassName参数代表的是需要被执行的类对象。一旦虚拟机启动完成后，就会首先调用这个类中的静态main(String[] args)方法。我们在前述小节中已经分析过AndroidRuntime::start中的大部分内容了，下面重点看一下与ZygoteInit相关的部分：

```
/*frameworks/base/core/jni/AndroidRuntime.cpp*/
void AndroidRuntime::start(const char* className, const Vector<St
{…
    char* slashClassName = toSlashClassName(className);
    jclass startClass = env->FindClass(slashClassName);
    if (startClass == NULL) {
        ALOGE("JavaVM unable to locate class '%s'\n", slashClassN
        /* keep going */
    } else {
        jmethodID startMeth = env->GetStaticMethodID(startClass,
            "([Ljava/lang/String;)V");
        if (startMeth == NULL) {
            ALOGE("JavaVM unable to find main() in '%s'\n", class
            /* keep going */
        } else {
            env->CallStaticVoidMethod(startClass, startMeth, strA
        }
    }
    …
}
```

JniInvocation中的Init和startVM函数分别用于初始化和启动虚拟机，然后onVmCreated()会被回调来通知持有者虚拟机的最新状态。这些知识点我们在前面小节中已经分析过了，大家如有不清楚的地方可以回过头去阅读。

接下来AndroidRuntime::start就可以处理className（即这个场景中的ZygoteInit）了。首先把类名中的“.”全部转换成slash符号（“/”），得到如下的结果：

```
com/android/internal/os/ZygoteInit
```

这样做的目的之一是便于虚拟机根据类名来查找到类的存储地址。

如果读者用过Java反射机制，一定会对它的强大之处印象深刻。反射机制可以在运行阶段动态加载并实例化一个类对象，在某些场合下可以为程序提供非常灵活的实现。AndroidRuntime::start中对className的处理过程实际上与反射机制的原理是非常相似的。它们都需要回答下面的几个问题：

- 问题1. 如何快速查找到包含了目标类的Package包；
- 问题2. 如何加载并实例化className所指示的类对象。

与标准Java虚拟机不同，Android系统采用的是Dex文件格式，而且还需要考虑事先已经做好优化（odex或者OAT等）的情况。

另外，针对Art虚拟机还需要额外回答：

- 问题3. Java代码是如何与OAT中的Native Code准确对应起来的呢？

本小节接下来的内容中我们将给出上述3个问题的答案。

AndroidRuntime运行在JNI环境中，其中jclass、jstring、jobjectArray实际上是void*指针的typedef类型；env变量则属于JNIEnv类型，用于提供JNI环境下的各种处理函数。在这个场景中，查找className的关键在于env->FindClass。这个函数经过多层封装后，最终对应的是jni_internal.cc中的FindClass，核心实现如下所示：

```
/*art/runtime/jni_internal.cc*/
  static jclass FindClass(JNIEnv* env, const char* name) {
    …
    if (runtime->IsStarted()) {
      …
      c = class_linker->FindClass(soa.Self(), descriptor.c_str(),
    } else {
      c = class_linker->FindSystemClass(soa.Self(), descriptor.c_
    }
    return soa.AddLocalReference<jclass>(c);
  }
```

从上述代码段中可以看出FindClass将面临下面两种选择：

- runtime->IsStarted()为true的情况

IsStarted()用于指示当前的运行时环境是否已经启动成功，它是基于started_变量得出的结论，而这个变量在Runtime::Start()时会被置为true。

这种情况下我们可以调用class_linker的FindClass方法来查找目标类。

- 虚拟机运行时环境还未启动完成的情况

此时不能直接使用上述的方法，需要改由FindSystemClass（此时程序相关的Class还未进入Ready状态）来完成查找工作。

我们在前面初始化和启动虚拟机小节曾经分析过Class Linker，简单而言它扮演的是“类链接器”的角色——任何与目标程序以及虚拟机本身相关联的类、类中的方法等都属于它的管辖范围。换句话说，class_linker中的所有Class类、Jar包、甚至Dex、Image文件都可能成为FindClass的搜索范围。

首先来看下ClassLinker::FindClass（Thread* self, const char* descriptor, Handle<mirror:: ClassLoader> class_loader）函数参数的来源：

- Thread* self

JNIEnv对应的线程。

- char* descriptor

通过std::string descriptor(NormalizeJniClassDescriptor(name))转换而来。NormalizeJniClass Descriptor会把name中的“.”转换为“/”，其结果可能是：“La/b/C;”或者“[La/b/C;”。在我们这个场景下descriptor对应的是：com/android/internal/os/ ZygoteInit。

- Handle<mirror::ClassLoader> class_loader

类加载器。

诸如Handle<mirror::ClassLoader>这样的模板定义在虚拟机中还有很多，我们有必要做一下解释。对于那些从虚拟机的Heap中分配的对象，那么大家试想一下：如果系统中发生了GC，并且垃圾回收器挪动了对象的位置，那么原先那些指向老位置的变量该怎么办呢？这就是Handle的存在价值了。因为它所包含的元素对于GC是可见的，有利于后者对引用关系进行自动化的重新调整，而这一点显然是强指针所无法胜任的。

Handle通常是由HandleScopes分配的，譬如class_loader这个变量：

```
StackHandleScope<3> hs(self);
Handle<mirror::ClassLoader> class_loader(hs.NewHandle(klass->
```

我们首先创建了一个StackHandleScope变量，它是一个模板类，所带的数字表示所能容纳和管理的Handle上限。从StackHandleScope这个名称可以推断出，它是一个局部的栈对象，因而不能通过new等方式创建。而且当这个栈对象的生命周期结束后，其所管理的Handle也会被释放。

Handle具体是由NewHandle负责生成的，如下所示：

```
/*art/runtime/handle_scope-inl.h*/
template<size_t kNumReferences> template<class T>
inline MutableHandle<T> StackHandleScope<kNumReferences>::NewHand
  SetReference(pos_, object);
  MutableHandle<T> h(GetHandle<T>(pos_));
  pos_++;
  return h;
}
```

其中NewHandle的函数入参是klass->GetClassLoader()，即ClassLoader*。这就是需要通过Handle管理的对象，NewHandle首先会调用SetReference来表示它被引用了（pos_是一个unsigned int值）。紧接着我们需要提供一个容器MutableHandle，后者继承自Handle类。GetHandle的实现并不复杂，如下：

```
/*art/runtime/handle_scope-inl.h*/
inline Handle<mirror::Object> HandleScope::GetHandle(size_t i) {
  DCHECK_LT(i, number_of_references_);
  return Handle<mirror::Object>(&GetReferences()[i]);
```

```
}
```

可见它是利用GetReferences()来获取一个StackReference的指针，然后供生成的Handle来构造（Handle中有一个StackReference类型的变量reference_）。这样一来Handle中针对目标的操作在任何时候都可以保证是正确的了。

有了这些背景知识，现在我们可以进一步分析ClassLinker::FindClass的内部实现了：

```
/*art/runtime/class_linker.cc*/
mirror::Class* ClassLinker::FindClass(Thread* self, const char* d
                                      Handle<mirror::ClassLoader>
  …
  mirror::Class* klass = LookupClass(descriptor, class_loader.Get
  if (klass != nullptr) {
    return EnsureResolved(self, descriptor, klass);//成功找到Class
  }
  if (descriptor[0] == '[') { //情况2.class还未加载，且为数组类的情况
    return CreateArrayClass(self, descriptor, class_loader);
  } else if (class_loader.Get() == nullptr) {//情况3. Class是非数组
                                            //同时class loader为空
    ClassPathEntry pair = FindInClassPath(descriptor, boot_class_
                                            //搜寻boot class 路径
    if (pair.second != nullptr) {
      return DefineClass(self, descriptor, hash, NullHandle<mirro
                         *pair.first, *pair.second);
    } else {…
    }
  } else if (Runtime::Current()->UseCompileTimeClassPath()){//情况
    …
  } else {//情况5.ClassLoader不为空的情况
    ScopedObjectAccessUnchecked soa(self);
    mirror::Class* klass = FindClassInPathClassLoader(soa, self,
                                                      class_loade
    if (klass != nullptr) {
      return klass;
    }
ScopedLocalRef<jobject> class_loader_object(soa.Env(),
                        soa.AddLocalReference<jobject>(class_load
    std::string class_name_string(DescriptorToDot(descriptor));
    ScopedLocalRef<jobject> result(soa.Env(), nullptr);
    {
      ScopedThreadStateChange tsc(self, kNative);
      ScopedLocalRef<jobject> class_name_object(soa.Env(),
                              soa.Env()->NewStringUTF(class_name_
```

```
      if (class_name_object.get() == nullptr) {
        DCHECK(self->IsExceptionPending());  // OOME.
        return nullptr;
      }
      CHECK(class_loader_object.get() != nullptr);
      result.reset(soa.Env()->CallObjectMethod(class_loader_objec
                                  WellKnownClasses::java_lang_Class
                                           class_name_object.get())
    }
    if (self->IsExceptionPending()) {…
    } else if (result.get() == nullptr) {…
    } else {
      // success, return mirror::Class*
      return soa.Decode<mirror::Class*>(result.get());
    }
  }
  …
}
```

FindClass函数的目标很明确，就是为了找到descriptor所对应的Class实现，然后将其加载到内存中并转化为Class对象。

首先，FindClass会通过LookupClass确认这个Class是否已经被成功加载过。如果答案是肯定的话，直接从ClassLoader对应的Class Table（如果ClassLoader为空的话，则使用boot_class_table_）中返回正确的值。否则就进入情况2——数组类的判断中。不过我们这个场景下显然不属于后面这种情况，因而可以直接跳过这一步。

接下来就进入非数组类的处理中了。又有如下几种可能性：

情况3：class_loader为空的情况

按照双亲委派的原则，此时可以调用FindInClassPath在Boot Class Path中尝试查找目标对象。具体需要处理哪些路径在前述小节中对此已经有过详细阐述，这里不再赘述。

FindInClassPath的内部实现并不复杂，它会在一堆DexFile中寻找哪个文件中包含了descriptor所描述的类——如果找到的话就返回一个ClassPathEntry对象。当然，找到ClassPath还只是万里长征的起点，我们仍需要进一步执行加载、实例化、初始化类对象等多个操作才能真正让这个Class类变成可用状态。Class Linker也提供了各种包装函数（如DefineClass）来完成这一系列操作，后续我们再针对这些知识做

详细分析。

情况4：编译时特别指定了类路径的情况

UseCompileTimeClassPath 这个函数直接返回use_compile_time_class_path_变量值，而后者实际上与dex2oat的调用参数中是否含有“-Ximage:”有关。换句话说，只有承载dex2oat的虚拟机实例才会有Compile Time Class Path。

情况5：即便上述几种情况都无法找到正确的类，FindClass也还未到“山穷水尽”的地步。它会接着尝试调用FindClassInPathClassLoader，而这个函数所做的努力又分为两个方向：

其一，寻找boot_class_path_下的所有DexFile。

其二，寻找PathClassLoader中包含的DexPathList中的所有Dex元素，如下所示：

```
public class BaseDexClassLoader extends ClassLoader {
    private final DexPathList pathList;
```

而DexPathList管理的Dex文件保存在其下的dexElements数组中，即：

```
private Element[] dexElements;
```

这样一来，应用程序自身加载的Dex就可以在此时发挥作用了。

如果FindClassInPathClassLoader依然没有收获的话，程序才会通过class_loader自定义的loadClass来加载目标类对象。而假若这根“最后的稻草”仍然“一无所获”的话，那么FindClass就只能返回空指针了，并且还会引发“Class Not Found”类的错误。

紧接着我们再具体分析一下FindInClassPath的内部实现：

```
/*art/runtime/class_linker.cc*/
ClassPathEntry FindInClassPath(const char* descriptor,
                               size_t hash, const std::vector<const De
  {for (const DexFile* dex_file : class_path) {
```

```
    const DexFile::ClassDef* dex_class_def = dex_file->FindClassD
    if (dex_class_def != nullptr) {
      return ClassPathEntry(dex_file, dex_class_def);
    }
  }
  return ClassPathEntry(nullptr, nullptr);
}
```

可以看到，这个函数的返回值是ClassPathEntry，它其实是对DexFile文件位置的一种描述方式。查找过程也并不复杂，直接遍历class_path中的所有dex文件就可以了。其中最关键的还是FindClassDef这个函数：

```
/*art/runtime/dex_file.cc*/
const DexFile::ClassDef* DexFile::FindClassDef(const char* descri
  DCHECK_EQ(ComputeModifiedUtf8Hash(descriptor), hash);
  // If we have an index lookup the descriptor via that as its co
  Index* index = class_def_index_.LoadSequentiallyConsistent();
  if (index != nullptr) {
    auto it = index->FindWithHash(descriptor, hash);
    return (it == index->end()) ? nullptr : it->second;
  }
  // Fast path for rate no class defs case.
  uint32_t num_class_defs = NumClassDefs();
  if (num_class_defs == 0) {
    return nullptr;
  }
  // Search for class def with 2 binary searches and then a linea
  const StringId* string_id = FindStringId(descriptor);
  if (string_id != nullptr) {
    const TypeId* type_id = FindTypeId(GetIndexForStringId(*strin
    if (type_id != nullptr) {
      uint16_t type_idx = GetIndexForTypeId(*type_id);
      for (size_t i = 0; i < num_class_defs; ++i) {
        const ClassDef& class_def = GetClassDef(i);
        if (class_def.class_idx_ == type_idx) {
          return &class_def;
        }
      }
    }
  }
  …
}
```

大家还记得我们前面小节分析过的DexFile文件格式吗？它的Header中有一个成员变量class_defs_size_专门用于指示当前DexFile

中包含的Class的数量；而另一个成员变量class_defs_off_则指向用于描述各个Class具体信息的数组。

这样一来，查找某Class是否存在于DexFile中就很简单了。不过FindClassDef函数中很大一部分比重的代码其实是为了让整个查找过程更加高效，有兴趣的读者可以自行分析一下。而我们最关心的是查找过程是如何执行的，这部分涉及的核心语句如下：

```
for (size_t i = 0; i < num_class_defs; ++i) {
  const ClassDef& class_def = GetClassDef(i);
  if (class_def.class_idx_ == type_idx) {
    return &class_def;
  }
}
```

其中num_class_defs得到的就是class_defs_size_；GetClassDef(i)对应的是class_defs_[idx]，而且这个数组实际上就是通过class_defs_off_偏移量得到的。还需要特别注意的是type_idx这个变量，它的数据类型是uint16_t（即unsigned int）。从字面意思上理解代表的是Class的“序号”，那么它具体又是如何被计算出来的呢？答案在于下面这3个语句中：

```
onst StringId* string_id = FindStringId(descriptor);
const TypeId* type_id = FindTypeId(GetIndexForStringId(*string_id
uint16_t type_idx = GetIndexForTypeId(*type_id);
```

descriptor在我们这个场景中对应的是com/android/internal/os/ZygoteInit。FindStringId实际上是去查找DexFile中偏移量为string_ids_off_的一个StringId数组中descriptor所对应的数组项。StringId这个结构体中的string_data_off_指向的是一个String字符串，这样就可以与descriptor进行字符串匹配了。GetIndexForStringId得到的是descriptor在StringId数组中的具体序号（这里获取序号的方式比较奇怪）。FindTypeId得到与StringId对应的TypeId，而GetIndexForTypeId则是TypeId在type_ids_数组中的序号。

得到正确的ClassDef后，接下来就可以构建ClassPathEntry了，这个对象实际上是对std::pair<const DexFile*, const DexFile::ClassDef*>的typedef。

不过工作还没有完成，这一点从Class的状态表中也可以看出来：

```
/*art/runtime/mirror/Class.h*/
enum Status {
    kStatusRetired = -2,  // Retired, should not be used. Use the
    kStatusError = -1,
    kStatusNotReady = 0,
    kStatusIdx = 1,  // Loaded, DEX idx in super_class_type_idx_
    kStatusLoaded = 2,  // DEX idx values resolved.
    kStatusResolving = 3,  // Just cloned from temporary class ob
    kStatusResolved = 4,  // Part of linking.
    kStatusVerifying = 5,  // In the process of being verified.
    kStatusRetryVerificationAtRuntime = 6,  // Compile time verif
    kStatusVerifyingAtRuntime = 7,  // Retrying verification at r
    kStatusVerified = 8,  // Logically part of linking; done pre-
    kStatusInitializing = 9,  // Class init in progress.
    kStatusInitialized = 10,  // Ready to go.
    kStatusMax = 11,
  };
```

kStatusNotReady:如果FindClass无法查找到目标类，那么我们需要分配一个Class对象，并将状态迁移到kStatusNotReady。

kStatusIdx: 紧接着我们从DexFile中读取Class信息，用于填充上述的Class对象，并将状态迁移到kStatusIdx（表明super_class_还未填充），而且此时的Class可以被插入ClassTable中

kStatusLoaded: 如果获取Class锁成功，我们就可以调用ResolveClass来将状态迁移到kStatusLoaded了（此时super_class_已经处理）。

kStatusResolved: 此状态表明linking已经完成。

上述各状态数值的大小就代表了它们在状态机中的变迁逻辑，其中核心的几个状态变迁关系如图21-66所示。

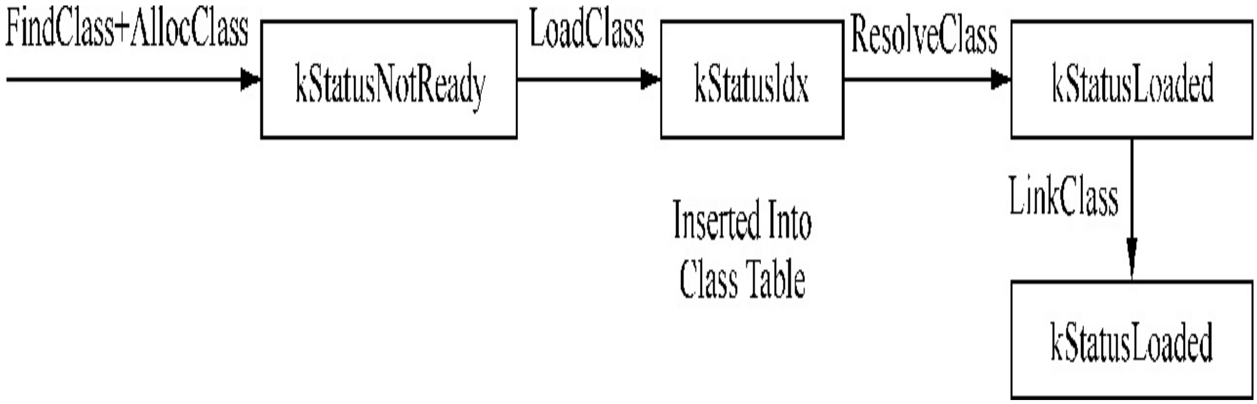

▲图21-66　Class的核心状态变迁

所以说查找到目标对象只是第一步，我们还得经历上述的核心状态迁移才能最终让Class达到可用状态，这些工作大多是在DefineClass中完成的：

```
/*art/runtime/class_linker.cc*/
mirror::Class* ClassLinker::DefineClass(Thread* self,
                                        const char* descriptor,
                                        size_t hash,
                                        Handle<mirror::ClassLoader> cla
                                        const DexFile& dex_file,
                                        const DexFile::ClassDef& dex_cl
  StackHandleScope<3> hs(self);
  auto klass = hs.NewHandle<mirror::Class>(nullptr);

  …
  if (klass.Get() == nullptr) {
    // 分配一个Class空间，并将状态迁移到kStatusNotReady
    klass.Assign(AllocClass(self, SizeOfClassWithoutEmbeddedTable
                            dex_class_def)));
  }
  …
  mirror::DexCache* dex_cache = RegisterDexFile(dex_file,
      GetOrCreateAllocatorForClassLoader(class_loader.Get()));
  …
  klass->SetDexCache(dex_cache);
  SetupClass(dex_file, dex_class_def, klass, class_loader.Get());

  // Mark the string class by setting its access flag.
  if (UNLIKELY(!init_done_)) {
    if (strcmp(descriptor, "Ljava/lang/String;") == 0) {
      klass->SetStringClass();
    }
```

```
  }

  ObjectLock<mirror::Class> lock(self, klass);
  klass->SetClinitThreadId(self->GetTid());

  // Add the newly loaded class to the loaded classes table.
  mirror::Class* existing = InsertClass(descriptor, klass.Get(),
  if (existing != nullptr) {//Table中已经存在此Class
    return EnsureResolved(self, descriptor, existing);
  }
  LoadClass(self, dex_file, dex_class_def, klass);
  …
  auto interfaces = hs.NewHandle<mirror::ObjectArray<mirror::Clas

  MutableHandle<mirror::Class> h_new_class = hs.NewHandle<mirror:
  if (!LinkClass(self, descriptor, klass, interfaces, &h_new_clas
    // Linking failed.
    if (!klass->IsErroneous()) {
      mirror::Class::SetStatus(klass, mirror::Class::kStatusError
    }
    return nullptr;
  }
  …
  }
  …
  return h_new_class.Get();
}
```

这个函数很长，核心的操作由AllocClass、SetDexCache、SetupClass、InsertClass、Ensure Resolved、LoadClass和LinkClass等组成。

其中AllocClass即“Allocate Class”，它负责申请Class对象所需的内存空间。而且这块内存是从Runtime::Current()->GetHeap()中获得的——这样一来就将它纳入GC的统一管理中了。需要分配的空间大小由SizeOfClassWithoutEmbeddedTables计算得到，有兴趣的读者可以自行分析其中的实现细节。

SetupClass简单来讲用于对Class对象进行初始化。InsertClass则负责将本次已经加载的Class保存到一个已加载列表中，这样后续如果再次使用时就不需要再“大费周章”了。根据这个函数的返回值可以判断出要插入的对象是否已经存在——正常情况下返回值是nullptr，但也有特例：譬如其他线程也在尝试做同一个Class的插入操作，而且比

我们先行完成了。当然，这种情况下我们还需要调用EnsureResolved来确保Class得到正确的解析处理。

LoadClass是将AllocClass申请的空间真正填满内容（成员变量、成员函数等）的一个函数，这也是后面Class中的函数能被正确执行的关键所在。代码实现如下：

```
/*art/runtime/class_linker.cc*/
void ClassLinker::LoadClass(Thread* self, const DexFile& dex_file
                            const DexFile::ClassDef& dex_class_def,
                            Handle<mirror::Class> klass) {
  const uint8_t* class_data = dex_file.GetClassData(dex_class_def
  if (class_data == nullptr) {
    return;  // no fields or methods - for example a marker inter
  }
  bool has_oat_class = false;
  if (Runtime::Current()->IsStarted() && !Runtime::Current()->IsA
    OatFile::OatClass oat_class = FindOatClass(dex_file, klass->G
                                                             &has_oat_class);
    if (has_oat_class) {
      LoadClassMembers(self, dex_file, class_data, klass, &oat_cl
    }
  }
  if (!has_oat_class) {
    LoadClassMembers(self, dex_file, class_data, klass, nullptr);
  }
}
```

首先我们需要从DexFile中找到Class数据（每个Class数据由class_data_item构成）所在位置，这个偏移量保存在class_data_off_中。假如这个值为空的话，代表当前的类并没有包含任何成员函数和成员变量，因而流程可以直接结束。紧接着查找这个Dex Class所对应的OatClass，判断规则是它们的index值是否一致。具体来说，我们需要调用klass->GetDexClassDefIndex来得到Dex Class的序号，然后利用FindOatClass来获得Oat Class对象。当然，执行这种对应关系的前提是Runtime已经启动，并且IsAotCompiler的返回值是false——即非AOT编译器的情况。什么意思呢？就是指当前的进程首先不能是一个Compiler（或者说当前进程不是dex2oat），而且没有使用JIT在做编译。所以对于一般的Android程序来说都会执行这个代码分支。

不管有没有Oat Class,程序都会调用LoadClassMembers。我们来看一下这个函数的内部实现：

```
/*art/runtime/class_linker.cc*/
void ClassLinker::LoadClassMembers(Thread* self, const DexFile& d
                             const uint8_t* class_data,
                             Handle<mirror::Class> klass,
                             const OatFile::OatClass* oat_class)
  {
    ClassDataItemIterator it(dex_file, class_data);
    //加载静态成员变量
    const size_t num_sfields = it.NumStaticFields();
    ArtField* sfields = num_sfields != 0 ?
                                 AllocArtFieldArray(self, num_sfi
    for (size_t i = 0; it.HasNextStaticField(); i++, it.Next()) {
      CHECK_LT(i, num_sfields);
      LoadField(it, klass, &sfields[i]);
    }
    klass->SetSFields(sfields);
    klass->SetNumStaticFields(num_sfields);
    DCHECK_EQ(klass->NumStaticFields(), num_sfields);
    //加载普通成员变量
    const size_t num_ifields = it.NumInstanceFields();
    ArtField* ifields = num_ifields != 0 ?
                              AllocArtFieldArray(self, num_ifield
    for (size_t i = 0; it.HasNextInstanceField(); i++, it.Next())
      CHECK_LT(i, num_ifields);
      LoadField(it, klass, &ifields[i]);
    }
    klass->SetIFields(ifields);
    klass->SetNumInstanceFields(num_ifields);
    DCHECK_EQ(klass->NumInstanceFields(), num_ifields);
    //加载成员函数，根据函数类型的不同，加载方式也会有区别
    if (it.NumDirectMethods() != 0) {//static、private等类型的函数
      klass->SetDirectMethodsPtr(AllocArtMethodArray(self, it.Num
    }
    klass->SetNumDirectMethods(it.NumDirectMethods());//Direct Me
    if (it.NumVirtualMethods() != 0) {//加载虚函数
      klass->SetVirtualMethodsPtr(AllocArtMethodArray(self,it.Num
    }
    klass->SetNumVirtualMethods(it.NumVirtualMethods());//虚函数数
    size_t class_def_method_index = 0;
    uint32_t last_dex_method_index = DexFile::kDexNoIndex;
    size_t last_class_def_method_index = 0;
    for (size_t i = 0; it.HasNextDirectMethod(); i++, it.Next())
      ArtMethod* method = klass->GetDirectMethodUnchecked(i, imag
      LoadMethod(self, dex_file, it, klass, method);
      LinkCode(method, oat_class, class_def_method_index);
      uint32_t it_method_index = it.GetMemberIndex();
      if (last_dex_method_index == it_method_index) {
        // duplicate case
```

```
        method->SetMethodIndex(last_class_def_method_index);
      } else {
        method->SetMethodIndex(class_def_method_index);
        last_dex_method_index = it_method_index;
        last_class_def_method_index = class_def_method_index;
      }
      class_def_method_index++;
    }
    for (size_t i = 0; it.HasNextVirtualMethod(); i++, it.Next())
      ArtMethod* method = klass->GetVirtualMethodUnchecked(i, ima
      LoadMethod(self, dex_file, it, klass, method);
      DCHECK_EQ(class_def_method_index, it.NumDirectMethods() + i
      LinkCode(method, oat_class, class_def_method_index);
      class_def_method_index++;
    }
    DCHECK(!it.HasNext());
  }
  self->AllowThreadSuspension();
}
```

LoadMembers可以分为3个部分，分别负责加载静态成员变量、普通成员变量和成员函数。ClassDataItemIterator是一个Iterator，它的每一项都对应一个class_data_item。NumStaticFields返回的是当前Class中静态变量的数量，它是在如下构造函数中赋值的：

```
  ClassDataItemIterator(const DexFile& dex_file, const uint8_t* r
      : dex_file_(dex_file), pos_(0), ptr_pos_(raw_class_data_ite
    ReadClassDataHeader();
    if (EndOfInstanceFieldsPos() > 0) {
      ReadClassDataField();
    } else if (EndOfVirtualMethodsPos() > 0) {
      ReadClassDataMethod();
    }
  }
```

ReadClassDataHeader将从ptr_pos_，即raw_class_data_item所指向的区域中读取变量和函数的数量，并保存到header_中。对于加载到的所有信息，都将通过kclass这个变量进行保存，以便后面的代码执行可以顺利进行。

我们再回到DefineClass函数的分析中。LoadClass之后还剩最后一步操作，即LinkClass。它也是ClassLinker的意义所在——建立各个Class之间的关联。比如父子类之间是如何重载的，实现多态性的VTable和ITable应该怎么处理等。

以LinkClass中的LinkMethods为例，它的主要工作是处理好多态性的实现。多态允许程序在运行中再绑定具体的函数，给程序带来了很多灵活性和便利性。多态的具体实现虽然与编译器有关联，但是它们的基本原理都是类似的。当我们在Class中定义一个虚函数（严格来讲，Java没有虚函数的概念，或者说函数默认就具有虚函数的行为）的时候，Compiler会为它添加一个隐藏的成员变量，而后者会指向一个函数指针数组。这个数组就是被大家所熟知的VTable（Virtual Method Table），它包含的各个指针的具体值需要在运行时才能得到最终确定：

```
bool ClassLinker::LinkMethods(Thread* self,
                              Handle<mirror::Class> klass,
                              Handle<mirror::ObjectArray<mirror::Class
                              ArtMethod** out_imt) {
  self->AllowThreadSuspension();
  return SetupInterfaceLookupTable(self, klass, interfaces)
          && LinkVirtualMethods(self, klass, /*out*/ &default_tra
          && LinkInterfaceMethods(self, klass, default_translatio
}
```

LinkMethods的处理主要分为两个步骤：其一是先链接虚函数，然后再链接接口中的函数。链接的本质就是把对函数的索引号引用变成真正的目的地址，以便程序的正确执行。

LinkVirtualMethods用于对虚函数进行处理，它在执行逻辑上会分为两个部分（分别对应函数实现中的if和else两个分支）——即当前类是否有自己的SuperClass。我们知道，Java语言中只有“最顶端”的Object才允许没有父类，因而对绝大多数的类来说，它们都会走前半部分的分支。这种情况下，当前类的VTable首先是从父类获取到的，然后以此为基础进行“改造”。

VTable在代码实现中采用的是mirror::PointerArray数据结构。这个Array的最大值是num_virtual_methods + super_vtable_length，也就是父类中已有的数组大小加上类自身的虚函数个数。我们给VTable分配的空间大小（AllocPointerArray）也是以这个数为基准的。VTable的初始化也很简单，就是将Super Class中的各个entry复制到VTable中来。而且如果num_virtual_methods为0，说明这个函数并不需要再做其他额外工作，那么这种情况下函数可以直接结束返回。

VTable完成初始化后，接下来就需要处理当前类中的情况了。我们

可以来思考一下，如何分步骤来完成对VTable的改造呢？实际上无非就是两个原则：

- 查询Super Class的VTable是否有被这个类override的函数；
- 对于那些与父类没有直接关系的新函数，添加到VTable的末尾。

LinkVirtualMethods的核心处理流程也是遵照上面这两点展开的，只不过出于性能等因素的考虑，它还加入了很多其他改进措施。有兴趣的读者可以自行阅读代码了解。

理解了VTable的处理过程后，我们再来进一步分析IfTable。相信很多读者会有这样的疑问，既然已经有了VTable，为什么还需要IfTable呢？

IfTable从字面上很容易理解，是指Interface Table，它对应的代码实现是：

```
HeapReference<IfTable> iftable_;
```

而IfTable数据结构定义如下：

```
class MANAGED IfTable FINAL : public ObjectArray<Object> {…
```

简单来说，Iftable是多个Interface和其对应的method列表的集合。

根据Java语言的规定，一个Class虽然只能继承自（extends）一个类，但却可以实现（implements）多个接口。如图21-67所示。

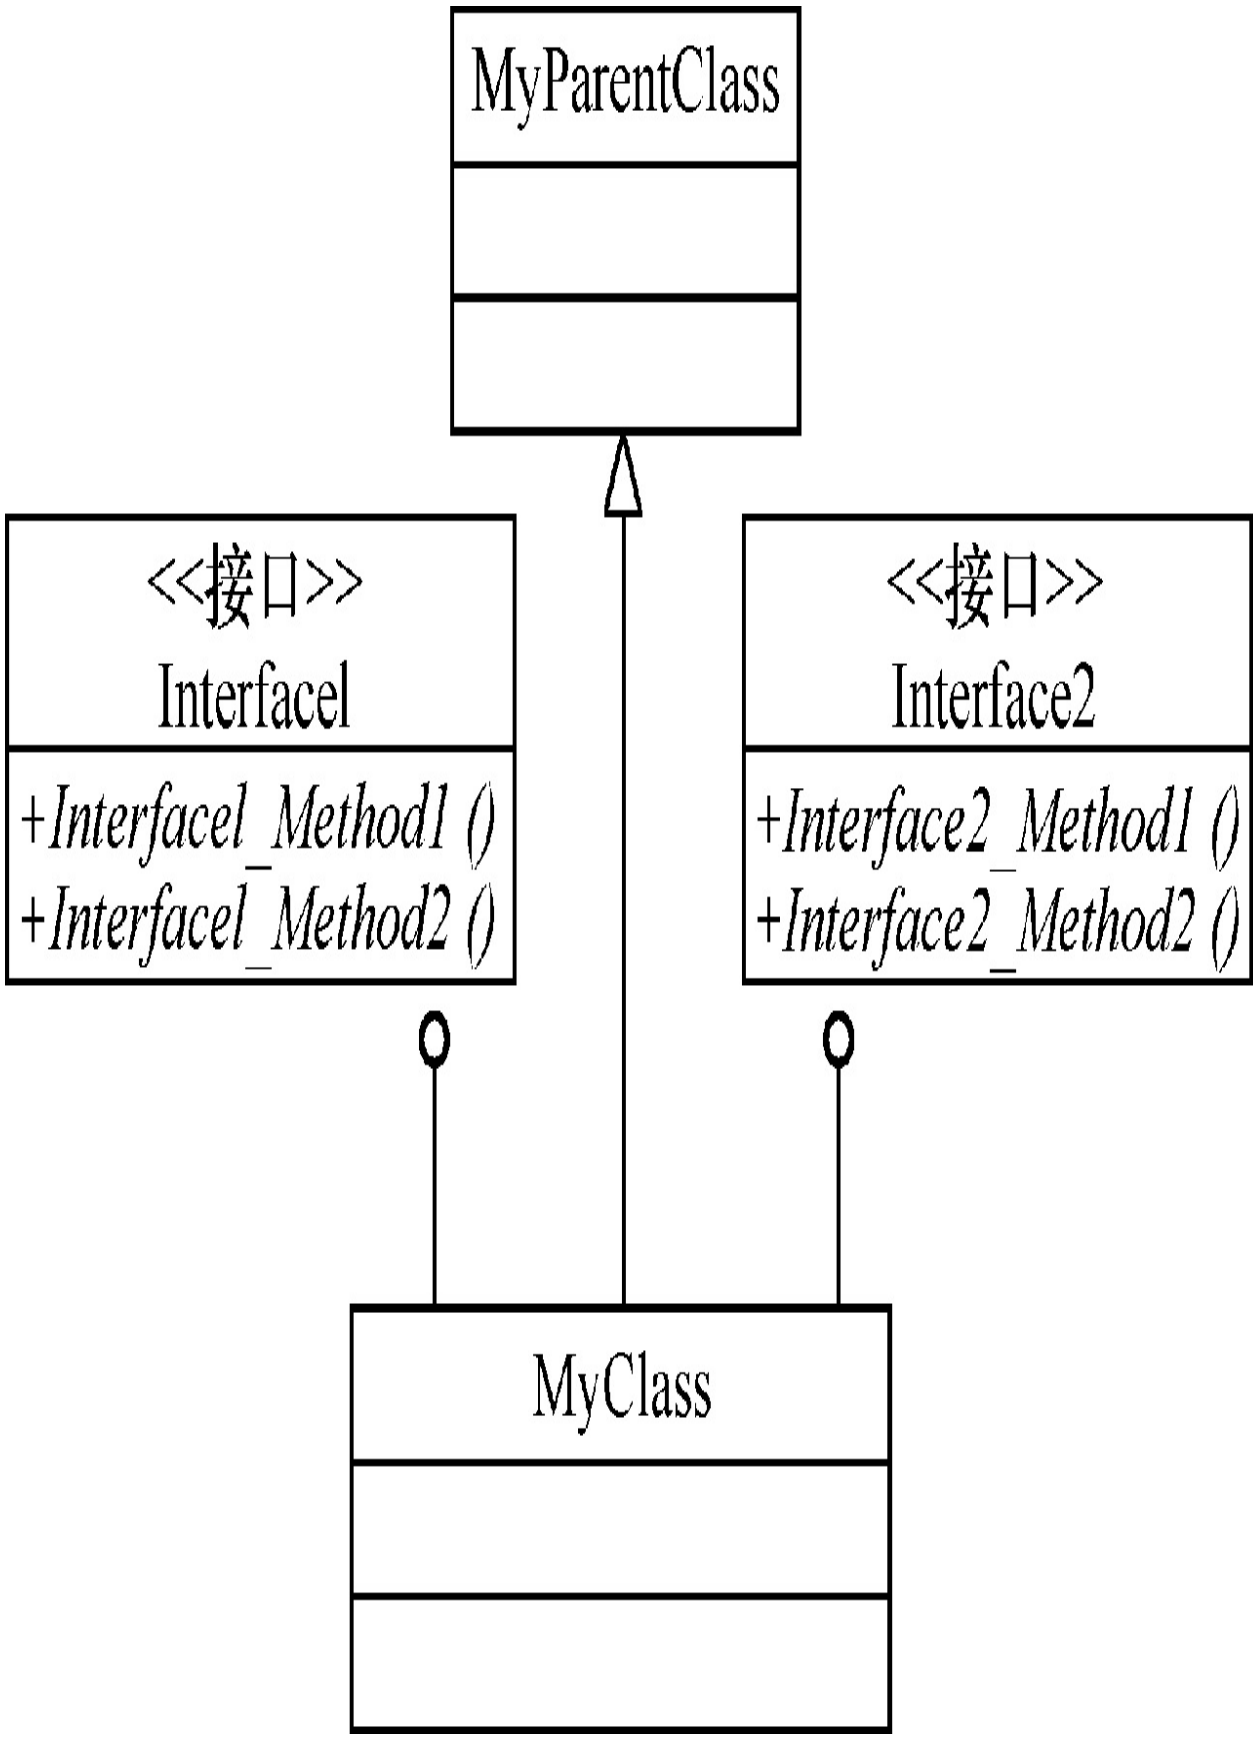
MyParentClass
<<接口>>
Interface1
+Interface1_Method1 ()
+Interface1_Method2 ()
<<接口>>
Interface2
+Interface2_Method1 ()
+Interface2_Method2 ()
MyClass

▲图21-67 Java类的继承与实现

这一点我们从两个Table的定义对比也可以窥见一二：

```
HeapReference<IfTable> iftable_;
HeapReference<PointerArray> vtable_;
```

其中IfTable继承自ObjectArray<Object>：

```
class MANAGED IfTable FINAL : public ObjectArray<Object> {
```

所以说VTable只解决类的extends关系，而不负责类的implements关系，后者的实现就交由IfTable来完成了。

这样一来，FindClass的整个实现过程就分析完成了。

得到Class对象之后，下一步需要理解的是怎么执行Class类中的函数。为了便于大家阅读，我们再将start函数中的相关代码摘取如下：

```
    jclass startClass = env->FindClass(slashClassName);
    if (startClass == NULL) {
        ALOGE("JavaVM unable to locate class '%s'\n", slashClassN
        /* keep going */
    } else {
        jmethodID startMeth = env->GetStaticMethodID(startClass,
            "([Ljava/lang/String;)V");
        if (startMeth == NULL) {
            ALOGE("JavaVM unable to find main() in '%s'\n", class
            /* keep going */
        } else {
            env->CallStaticVoidMethod(startClass, startMeth, strA
        }
    }
```

Zygote希望AndroidRuntime启动的Class类是com.android.internal.os.ZygoteInit，入口函数则是“main”。因而AndroidRuntime::start首先通过GetStaticMethodID来从上述加载的startClass中获得main函数的jmethodID。这个ID值是后续main函数能得到顺利运行的前提条件（它实际上是一个_jmethodID指针）。GetStaticMethodID的源码实现在jni_internal.cc中，如下所示：

```
/*art/runtime/jni_internal.cc*/
  static jmethodID GetStaticMethodID(JNIEnv* env, jclass java_cla
                              const char* sig) {
    CHECK_NON_NULL_ARGUMENT(java_class);
    CHECK_NON_NULL_ARGUMENT(name);
    CHECK_NON_NULL_ARGUMENT(sig);
    ScopedObjectAccess soa(env);
    return FindMethodID(soa, java_class, name, sig, true);
  }
```

CHECK_NON_NULL_ARGUMENT宏用于确保参数不为空，否则函数直接结束并返回null。可见起主要作用的是最后的FindMethodID：

```
/*art/runtime/jni_internal.cc*/
static jmethodID FindMethodID(ScopedObjectAccess& soa, jclass jni
                        const char* name, const char* sig, bool i
SHARED_LOCKS_REQUIRED(Locks::mutator_lock_) {
mirror::Class* c = EnsureInitialized(soa.Self(),
                               soa.Decode<mirror::Class*>(jni_cla
…
  ArtMethod* method = nullptr;
  auto pointer_size = Runtime::Current()->GetClassLinker()->GetIm
  if (is_static) {
    method = c->FindDirectMethod(name, sig, pointer_size);
  } else if (c->IsInterface()) {
    method = c->FindInterfaceMethod(name, sig, pointer_size);
  } else {
    method = c->FindVirtualMethod(name, sig, pointer_size);
    …
  }
  …
  return soa.EncodeMethod(method);
}
```

这个函数的目标是根据参数name来查找到正确的methodID。在我们这个场景中，name对应的是“main”，而且is_static等于true（因为main是静态函数）。换句话说，上述代码段中真正调用的实现函数是FindDirectMethod：

```
/*art/runtime/mirror/Class.cc*/
ArtMethod* Class::FindDirectMethod(const StringPiece& name,
                               const StringPiece& signature, size
  for (Class* klass = this; klass != nullptr; klass = klass->GetS
    ArtMethod* method = klass->FindDeclaredDirectMethod(name, sig
                                                    pointer_size)
```

```
    if (method != nullptr) {
      return method;
    }
  }
  return nullptr;
}
```

查找Direct Method的过程并不复杂，就是按照继承关系不断搜寻。FindDeclaredDirectMethod最终是通过Class中的direct_methods_数组来找到所需的ArtMethod的，其中signature代表函数的原型——例如main函数对应的是“([Ljava/lang/String;]V”。Class中的成员变量direct_methods_是Class Linker为目标Class加载数据时赋值的，具体而言是在LoadClassMembers中调用SetDirectMethodsPtr实现的。建议大家可以和前面介绍的内容结合起来分析，相信会有更深刻的理解。

找到的ArtMethod指针会通过jmethodID数据结构包装后再返回给GetStaticMethodID，进而为startMeth赋值。JNI中自定义了不少类似于jmethodID的数据结构（如jfieldID、jobject、jclass等），它们大多数是对基础数据类型的typedef（如void*）。那么jmethodID只是对ArtMethod*简单的强制类型转换吗？我们发现FindMethodID最后return的是EncodeMethod(method）。它和另一个配套的DecodeMethod的声明如下：

```
jmethodID EncodeMethod(mirror::ArtMethod* method) const;
mirror::ArtMethod* DecodeMethod(jmethodID mid) const;
```

也就是说，“编解码”之间的关系如下：

```
Encode: ArtMethod->jmethodID; Decode: jmethodID->ArtMethod
```

获取到Method Id后，接下来就要考虑如何才能真正地执行这个函数。在我们这个场景下，运行main函数所使用的JNI接口是CallStaticVoidMethod：

```
/*art/runtime/jni_internal.cc*/
  static void CallStaticVoidMethod(JNIEnv* env, jclass, jmethodID
    va_list ap;
    va_start(ap, mid);
    CHECK_NON_NULL_ARGUMENT_RETURN_VOID(mid);
    ScopedObjectAccess soa(env);
    InvokeWithVarArgs(soa, nullptr, mid, ap);
    va_end(ap);
```

```
  }
```

因为所要被执行的函数事先是未知的，函数所带的参数也是不确定的，所以CallStaticVoid Method采用的是不定参的格式。如果大家对这种类型的函数感到陌生的话，建议可以先自行查阅相关资料了解详情：

```
/*art/runtime/reflection.cc*/
JValue InvokeWithVarArgs(const ScopedObjectAccessAlreadyRunnable&
    SHARED_LOCKS_REQUIRED(Locks::mutator_lock_) {
  …
  mirror::ArtMethod* method = soa.DecodeMethod(mid);
  mirror::Object* receiver = method->IsStatic() ? nullptr :
                                          soa.Decode<mirror::Ob
  uint32_t shorty_len = 0;
  const char* shorty = method->GetShorty(&shorty_len);
  JValue result;
  ArgArray arg_array(shorty, shorty_len);
  arg_array.BuildArgArrayFromVarArgs(soa, receiver, args);
  InvokeWithArgArray(soa, method, &arg_array, &result, shorty);
  return result;
}
```

因为传入的参数是jmethodID，所以需要先通过DecodeMethod把它转成正确的ArtMethod。我们知道，函数如果是静态的（IsStatic）话，那么可以不需要实例化就直接调用；反之就要指定它所对应的对象——在上述代码段中指的是receiver，它是由obj这个参数Decode而来的。另外，shorty字符串是对目标函数原型的描述，以便后续可以精确定位。

一切准备就绪以后，开始调用InvokeWithArgArray，而后者又会进一步调用ArtMethod::Invoke：

```
/*art/runtime/art_method.cc*/
void ArtMethod::Invoke(Thread* self, uint32_t* args, uint32_t arg
                                     JValue* result, const char*
  …
  ManagedStack fragment;
  self->PushManagedStackFragment(&fragment);
  Runtime* runtime = Runtime::Current();//注意，Runtime实例是进程唯一
  if (UNLIKELY(!runtime->IsStarted() || Dbg::IsForcedInterpreterN
this))) {…//当前Runtime还未启动，或者当前是调试模式下，那么需要使用interp
  } else {…//不需要解释器，直接执行函数对应的Native Code
    bool have_quick_code = GetEntryPointFromQuickCompiledCode() !
```

```
    if (LIKELY(have_quick_code)) {…
      if (!IsStatic()) {
        (*art_quick_invoke_stub)(this, args, args_size, self, res
      } else {
        (*art_quick_invoke_static_stub)(this, args, args_size, se
      }
      …
    }else {…//函数没有找到对应的Native Code，报错
    }
  }
  // Pop transition.
  self->PopManagedStackFragment(fragment);
}
```

ArtMethod::Invoke是虚拟机中最关键的函数之一，它有点类似于目标函数执行之前的“分发器”。这个函数很长，上述代码段是其中的核心实现。

它的处理逻辑如下：

- !runtime->IsStarted() || Dbg::IsForcedInterpreterNeededForCalling

如果runtime还没有启动完成，或者当前处于debug状态（这是因为调试程序时有可能需要单步执行或者Step into到函数内部，必须使用Interpreter才能完成），那么就走interpreter这个分支。Interpreter代表当前的函数由“解释器”来执行字节码，而不是直接调用通过dex2oat转化成的本地机器代码。

- 非interpreter的情况

大部分情况下，我们都可以直接执行已经被预先编译好的机器码，这也是保证Art虚拟机性能相较于Dalvik有较大幅度提升的基础条件之一

- 对于arm、i386等硬件平台架构，invoke将利用art_quick_invoke_stub或者art_quick_invoke_static_stub（静态函数的情况）来运行目标函数。不过这两个函数都只是做了一下简单的中转，它们会进一步调用quick_invoke_reg_setup来完成任务：

```
/*art/runtime/arch/arm/quick_entrypoints_cc_arm.cc*/
template <bool kIsStatic>
```

```
static void quick_invoke_reg_setup(ArtMethod* method, uint32_t* a
  uint32_t core_reg_args[4];  // r0 ~ r3
  uint32_t fp_reg_args[16];  // s0 ~ s15 (d0 ~ d7)
  uint32_t gpr_index = 1;  // Index into core registers. Reserve
  uint32_t fpr_index = 0;  // Index into float registers.
  uint32_t fpr_double_index = 0;  // Index into float registers f
  uint32_t arg_index = 0;  // Index into argument array.
  const uint32_t result_in_float = kArm32QuickCodeUseSoftFloat ?
      (shorty[0] == 'F' || shorty[0] == 'D') ? 1 : 0;//结果值是否涉

  if (!kIsStatic) {
    core_reg_args[gpr_index++] = args[arg_index++];
  }

  for (uint32_t shorty_index = 1; shorty[shorty_index] != '\0'; +
    char arg_type = shorty[shorty_index];
    if (kArm32QuickCodeUseSoftFloat) {
      arg_type = (arg_type == 'D') ? 'J' : arg_type;  // Regard d
      arg_type = (arg_type == 'F') ? 'I' : arg_type;  // Regard f
    }
    switch (arg_type) {
      case 'D': {…
      }
      case 'F':
        …
      case 'J':
        …
      default:
        if (gpr_index < arraysize(core_reg_args)) {
          core_reg_args[gpr_index++] = args[arg_index];
        }
        break;
    }
  }
  art_quick_invoke_stub_internal(method, args, args_size, self, r
                                result_in_float, core_reg_args,
}
```

上述这个函数的作用是为后续执行汇编代码准备好各种寄存器参数（它的函数名也很好地诠释了这一点），并将结果保存在core_reg_args和fp_reg_args中。其中core_reg_args负责处理通用功能部分，而fp_reg_args属于特殊寄存器，专门用于浮点数运算。浮点数在计算机中用于近似表示一个实数，由尾数、阶码和阶码的基数组成。IEEE754标准对浮点数的运算有严格规定，有兴趣的读者可以自行查阅学习。我们这里只需要知道符点数运算需要特殊寄存器的支持就可

以了。

我们在前面小节专门讲解过AAPCS——需要特别指出的是，Art虚拟机在调用汇编代码时并没有严格遵循AAPCS规则。这一点从invoke函数的处理流程中也可以看出来。在quick_invoke_reg_setup的实现中，core_reg_args数组大小为4，分别对应r0-r3这几个通用寄存器；fp_reg_args大小为16，对应的是s0-s15。另外，gpr_index、fpr_index和fpr_double_index是数组中的序号。另外，除了gpr_index需要预留r0给ArtMethod指针所以初始值为1外，其他数组的index都是从0开始计算的。

总体来说，各主要寄存器的作用如表21-12所示。

表21-12　寄存器的作用

Registers	Description
r0	指向目标函数（ArtMethod）的指针
r1	指向目标函数（ArtMethod）所需的参数数组（如果函数没有参数，则为null）
r2	上述参数数组的大小（bytes）
r3	指向当前线程的指针
[sp]	JValue* result
[sp + 4]	result_in_float的值

[sp + 8]	core register argument array
[sp + 12]	fp register argument array

对于非static的情况，quick_invoke_reg_setup首先复制args中的所有数据（指针）到core_reg_args数组中。接着进入一个for循环来逐一处理shorty字符串中的元素。shorty变量是通过ArtMethod::GetShorty获取到的，简单来说它是对函数原型的“简写”，表示（shorty的第0个元素代表的是函数的返回值，因而循环语句是从数组的序列1开始的）。表21-13展示的是常见的数据类型对应的简写，供大家参考。

表21-13　　数据类型对应的简写

数 据 类 型	简　　写
double	D
long	J
float	F
int	I
boolean	Z
char	C

byte	B
short	S
void	V
object	L如：Ljava/lang/String
array	[如：[Ljava/lang/String

如果在for循环语句对shorty的处理过程中发现了double和float，那么我们需要引入特殊寄存器fp_reg_args。不过在我们这个场景中（针对main函数的调用），并没有涉及浮点数的运算，所以可以直接略过。

针对寄存器的处理完成后，下面就要真正地去执行目标函数了，完成这一步操作的是art_quick_invoke_stub_internal。这个函数是由汇编代码编写而成的，它需要解决如下的核心问题点：

（1）如何调用和执行目标函数；

（2）函数结果值是如何传递的。

因为C函数quick_invoke_reg_setup调用art_quick_invoke_stub_internal时的实参格式如下：

```
art_quick_invoke_stub_internal(method, args, args_size, self, res
                                              result_in_float, core_reg_ar
```

根据ARM的ATPCS规范，C语言在调用汇编代码时的参数如果超过4个，那么余下部分就需要通过栈来传递。进入art_quick_invoke_stub_internal函数时具体的参数分布示意图如下所示：

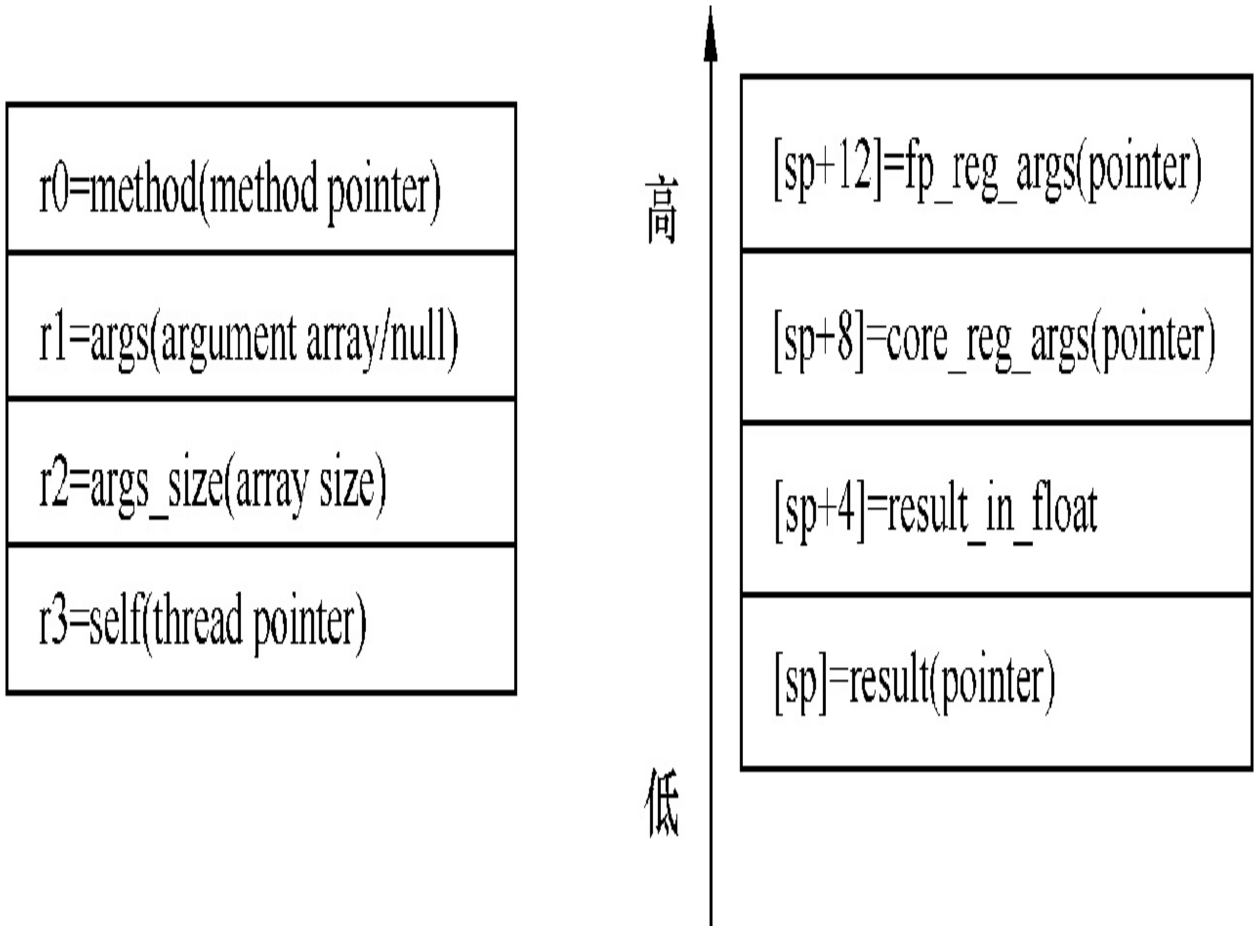

由上图可见，最终的函数结果值（result）将通过[sp]所指向的地址向外传递。大家在分析art_quick_invoke_stub_internal源码过程中也可以验证一下。

调用目标函数（在我们这个场景中指的是ZygoteInit：：main函数编译生成的Native Code）使用的是blx这条指令。ARM体系中常用的几种跳转指令包括：B、BL、BX、BLX和BXJ等。其中BL和BLX都会将PC（Program Counter）的下一个值保存到链接寄存器（Link Register）中，并且把需要跳转的目标地址存入PC寄存器中。

接下来我们逐行分析art_quick_invoke_stub_internal这个汇编函数，以帮助大家理解它的实现原理。其中标注了“.cfi*”的代码并不会影响函数的最终执行结果，因而可以直接略过。为了方便阅读，我们把所有分析都以注释的方式放在了相应代码行的后面，如下所示：

```
/*art/runtime/arch/arm/quick_entrypoints_arm.S*/
ENTRY art_quick_invoke_stub_internal
```

```
    SPILL_ALL_CALLEE_SAVE_GPRS      @将需要修改的寄存器(共9个)压栈，以便
    mov    r11, sp                  @ 将栈指针保存在r11中
    mov    r9, r3                   @ 将r3=method的值保存在r9中

    add    r4, r2, #4            @ r4=r2+4=args_size+4,需要额外分配4
    sub    r4, sp, r4            @ r4=sp-r4,预留所有参数所需要的空间，
    and    r4, #0xFFFFFFF0       @ 保证16字节对齐
    mov    sp, r4                @ sp=r4,即sp指向预留了空间并且做了对齐

    mov    r4, r0              @ 保存目标函数地址到r4中，因为r0立即要被
    add    r0, sp, #4          @ r0=sp+4，为memcpy准备参数。函数memcp
                               @ 带3个参数，r0对应dest,r1=args对应src
    bl     memcpy              @ 调用memcpy，从而把目标函数所需的参数全
    mov    ip, #0              @ ip=0
    str    ip, [sp]            @ [sp]=null，memcpy是从sp+4开始复制的，

    ldr    ip, [r11, #48]    @ ip=[r11+48],加载fp寄存器数组指针(注意之
                             @ 有读者可能会疑问怎么是#48呢？这是因为函数
                             @ SPILL_ALL_CALLEE_SAVE_GPRS压栈了9个寄
    vldm   ip, {s0-s15}      @ 将内存中的内容复制到 s0 - s15寄存器

    ldr    ip, [r11, #44]                @ ip=[r11+44],加载核心寄存器
    mov    r0, r4                        @ 还原r0为目标函数地址
    add    ip, ip, #4                    @ ip=ip+4,跳过4个字节
    ldm    ip, {r1-r3}                   @ 将内存中的内容复制到 r1 - r
    …
    ldr    ip, [r0, #Art_METHOD_QUICK_CODE_OFFSET_32]  @ 获取目标函
    blx    ip                            @ 调用目标函数
    mov    sp, r11                       @ 还原栈指针
    ldr    r4, [sp, #40]                 @ 加载 result_is_float
    ldr    r9, [sp, #36]                 @ 加载 result 指针
    cmp    r4, #0
    ite    eq
    strdeq r0, [r9]                      @ 将 r0/r1保存到result指针所
    vstrne d0, [r9]                      @ 将 s0-s1/d0保存到result指针

    pop    {r4, r5, r6, r7, r8, r9, r10, r11, pc}          @ 还原
END art_quick_invoke_stub_internal
```

寄存器的数量是非常有限的，而当我们需要占用到某些已经赋值了的寄存器时，可以先把它们保存到内存中，这个过程被称为寄存器溢出（Spill）。除了上述注释所示的内容外，我们还需要特别注意的是ART_METHOD_QUICK_CODE_OFFSET_32，它的定义如下：

```
/*art/runtime/asm_support.h*/
#define Art_METHOD_QUICK_CODE_OFFSET_32 36
```

```
ADD_TEST_EQ(Art_METHOD_QUICK_CODE_OFFSET_32,
         art::ArtMethod::EntryPointFromQuickCompiledCodeOffset(4)
```

那么这个宏定义的作用是什么呢？ADD_TEST_EQ可以为我们回答这个问题。这个函数会验证传入的两个参数（即ART_METHOD_QUICK_CODE_OFFSET_32和art::ArtMethod::EntryPointFromQuickCompiledCodeOffset(4).Int32Value()）是否相等，换句话说就是：

```
ART_METHOD_QUICK_CODE_OFFSET_32=

                           art::ArtMethod::EntryPointFromQuickCom
```

而EntryPointFromQuickCompiledCodeOffset函数的定义是：

```
  static MemberOffset EntryPointFromQuickCompiledCodeOffset(size_
    return MemberOffset(PtrSizedFieldsOffset(pointer_size) + OFFS
        PtrSizedFields, entry_point_from_quick_compiled_code_)
                / sizeof(void*) * pointer_size);
  }
```

绕了一个“大弯”，事实上EntryPointFromQuickCompiledCodeOffset所要获取的就是entry_point_from_quick_compiled_code_这个变量在ArtMethod类中的偏移量，以便art_quick_invoke_stub_internal中可以顺利跳转到它所指定的Entry Point中。

进入ART_METHOD_QUICK_CODE_OFFSET_32时的参数分布如图21-68所示。

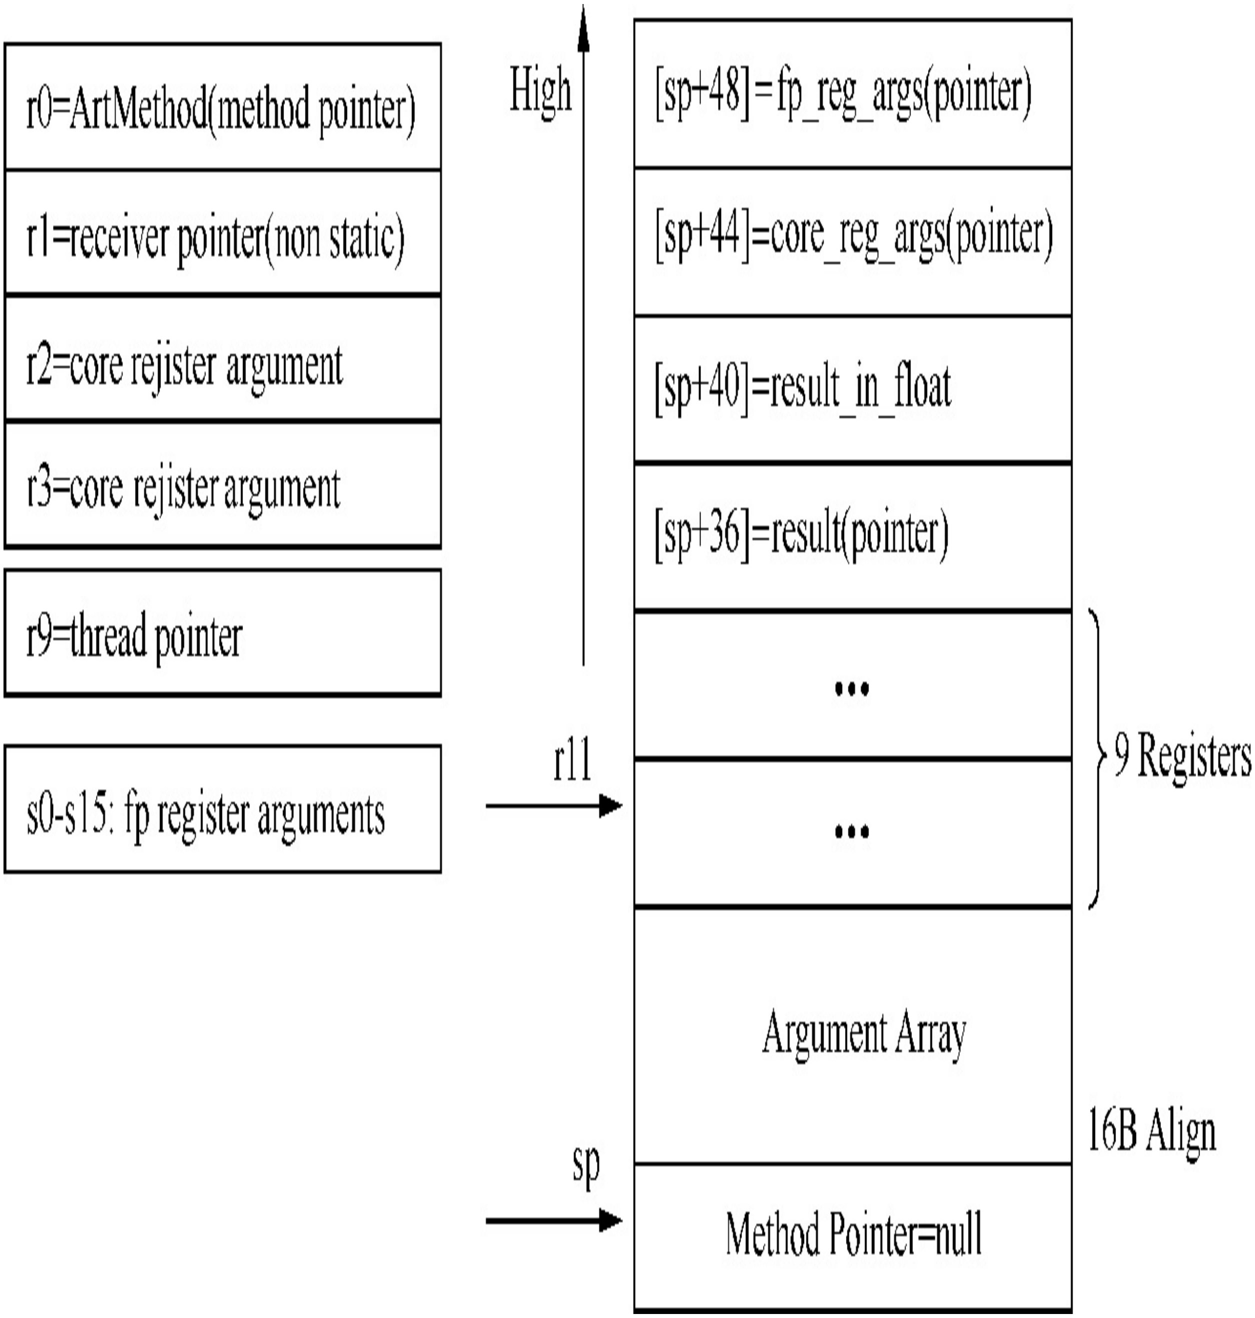

▲图21-68　参数分布

从前面小节针对Entry Point的学习我们知道，它的赋值取决于函数的实际情况——比如常见的一个值是art_quick_resolution_trampoline，如下所示：

```
ENTRY art_quick_resolution_trampoline
    SETUP_REFS_AND_ARGS_CALLEE_SAVE_FRAME r2, r3
    mov     r2, r9                      @ 从图21-68可知，r9代表的是当前的T
```

```
    mov     r3, sp                  @ 堆栈指针保存到r3中
    blx     artQuickResolutionTrampoline  @ (Method* called, rece
    cbz     r0, 1f                  @ is code pointer null? goto e
    mov     r12, r0
    ldr  r0, [sp, #0]               @ 将正确解析完成后的函数对象保存到r(
    RESTORE_REFS_AND_ARGS_CALLEE_SAVE_FRAME
    bx      r12                     @ 进入目标函数真正的入口地址
1:
    RESTORE_REFS_AND_ARGS_CALLEE_SAVE_FRAME
    DELIVER_PENDING_EXCEPTION
END art_quick_resolution_trampoline
```

这段汇编代码的关键点有两个，其一是调用artQuickResolutionTrampoline，其二是根据这个函数返回值（目标函数的真实地址）来开展工作。汇编函数art_quick_resolution_trampoline首先要为调用C函数artQuickResolutionTrampoline做好参数准备——因为类似于r9这样的寄存器是不符合C语言的调用规范的，必须先做处理。不难理解，它传递给后者的参数包括：r0=ArtMethod*(callee，但有可能为“伪目标”，参见后续分析），r1=receiver*(类的实例对象，仅非Static的情况下有效)，r2=r9=thread*，r3=sp=ArtMethod**。

接下来我们来详细解析artQuickResolutionTrampoline的内部实现。这个函数很长，我们采用分段阅读的方式：

```
/*art/runtime/entrypoints/quick/quick_trampoline_entrypoints.cc*/
extern "C" const void* artQuickResolutionTrampoline(
    ArtMethod* called, mirror::Object* receiver, Thread* self, Ar
    SHARED_LOCKS_REQUIRED(Locks::mutator_lock_) {…
  ClassLinker* linker = Runtime::Current()->GetClassLinker();
  ArtMethod* caller = QuickArgumentVisitor::GetCallingMethod(sp);
  InvokeType invoke_type;
  MethodReference called_method(nullptr, 0);
  const bool called_method_known_on_entry = !called->IsRuntimeMet
  if (!called_method_known_on_entry) {//called是否代表了真正的函数对多
    uint32_t dex_pc = caller->ToDexPc(QuickArgumentVisitor::GetCa
    const DexFile::CodeItem* code;
    called_method.dex_file = caller->GetDexFile();
    code = caller->GetCodeItem();
    CHECK_LT(dex_pc, code->insns_size_in_code_units_);
    const Instruction* instr = Instruction::At(&code->insns_[dex_
    Instruction::Code instr_code = instr->Opcode();
    bool is_range;
    switch (instr_code) {
```

```
      case Instruction::INVOKE_DIRECT:
        invoke_type = kDirect;
        is_range = false;
        break;
      case Instruction::INVOKE_DIRECT_RANGE:
        …其他case类同，直接省略
    }
    called_method.dex_method_index = (is_range) ? instr->VRegB_3r
    instr->VRegB_35c();
  } else {//虽然代表了真正的函数对象，但还未解析完成。比如Static函数
    invoke_type = kStatic;
    called_method.dex_file = called->GetDexFile();
    called_method.dex_method_index = called->GetDexMethodIndex();
  }
```

总体来说，程序中会有如下两种常见情况需要使用到artQuickResolutionTrampoline：

- 普通函数延迟解析

这有点类似于我们在前面学习到的动态链接库中的GOT/PLT机制——即只有当函数第一次被调用时才会去执行解析动作，而不是在一开始就完成所有函数的解析，这样做无疑可以提高程序的运行效率。

系统怎么区分出函数是第一次被调用呢？从上述代码段中不难发现，分水岭在于IsRuntime Method这个函数。它的内部实现只有一条语句，即：

```
dex_method_index_ == DexFile::kDexNoIndex
```

换句话说，Runtime Method这种类型的函数的最大特征是index值为无效的kDexNoIndex。

一旦程序判断出called指向的是一个Runtime Method，那么接下来的重点自然是：系统根据什么线索来找到真正的目标函数并替代这个“伪函数”呢？大家可以结合前面已经学习过的知识点，自行思考一下有哪些对我们有用的信息。

没错，就是调用者（caller）提供的字节码序列。因为invoke这个字节码命令本身是带有描述目标对象的参数的，如此一来我们只要沿着这一条“路径”就可以找到目标函数（保存在called_method中）所对

应的index值了。参考范例如下：

```
invoke-virtual {v4, v1}, Lcom/example/myapp/MyActivity;.setConten
```

- 静态函数延迟解析

前面在学习LinkCode时已经介绍过，Static函数因其特殊性需要用到延迟解析技术，对应的就是上述代码段中的else分支部分。因为此时called对象中的index已经代表了目标函数的索引值，意味着我们不需要再像前一种情况那样大费周章地去做查找工作了：

```
…
  const bool virtual_or_interface = invoke_type == kVirtual || in
  // Resolve method filling in dex cache.
  if (!called_method_known_on_entry) {
    StackHandleScope<1> hs(self);
    mirror::Object* dummy = nullptr;
    HandleWrapper<mirror::Object> h_receiver(
        hs.NewHandleWrapper(virtual_or_interface ? &receiver : &d
    DCHECK_EQ(caller->GetDexFile(), called_method.dex_file);
    called = linker->ResolveMethod(self, called_method.dex_method
  }
```

得到了目标函数的索引值后，接下来就可以利用ClassLinker提供的ResolveMethod来得到目标对象（ArtMethod）了。当然，只有当called_method_known_on_entry为false时才需要执行这一步操作：

```
  const void* code = nullptr;
  if (LIKELY(!self->IsExceptionPending())) {…
    if (virtual_or_interface) {…//虚函数或者接口函数，涉及多态性
      ArtMethod* orig_called = called;
      if (invoke_type == kVirtual) {
        called = receiver->GetClass()->FindVirtualMethodForVirtua

      } else {
        called = receiver->GetClass()->FindVirtualMethodForInterf

      }
      …
    } else if (invoke_type == kStatic) {//静态函数
      const auto called_dex_method_idx = called->GetDexMethodInde
      if (called->GetDexFile() == called_method.dex_file &&
          called_method.dex_method_index != called_dex_method_idx
        called->GetDexCache()->SetResolvedMethod(called_dex_metho
```

```
      }
    }
    // 目标函数所在类是否已经初始化过
    …
    linker->EnsureInitialized(soa.Self(), called_class, true, tru
    if (LIKELY(called_class->IsInitialized())) {//已经初始化过的情况
      if (UNLIKELY(Dbg::IsForcedInterpreterNeededForResolution(se
        code = GetQuickToInterpreterBridge();
      } else if (UNLIKELY(Dbg::IsForcedInstrumentationNeededForRe

        code = GetQuickInstrumentationEntryPoint();
      } else {
        code = called->GetEntryPointFromQuickCompiledCode();
      }
    } else if (called_class->IsInitializing()) {…//初始化未完成的情
    } else {
      DCHECK(called_class->IsErroneous());
    }
  }
  …
  *sp = called;
  return code;
}
```

相信大家已经从上述的代码段中看出了我们所面临的第二个障碍了，即多态性——此时需要根据this指针（即receiver）来判断函数是否被重载。大家可以自行学习FindVirtualMethodForVirtual和FindVirtualMethodForInterface来了解其中的实现细节。

最后，我们还需要利用ClassLinker的EnsureInitialized来确保目标函数所在的类是否已经成功初始化。以初始化完成的情况为例，此时就可以确定出目标函数的入口地址了。

如果是因为调试的原因需要强制使用Interpreter，那么入口地址会被设置为GetQuick ToInterpreterBridge；如果是需要启用Instrumentation（后续小节有专门介绍）的情况，入口地址会被设置为GetQuickInstrumentationEntryPoint；否则入口地址是GetEntryPointFromQuick CompiledCode。

我们需要注意函数结尾的如下几行语句：

```
  *sp = called;
```

```
  return code;
}
```

第一行语句表示sp栈顶位置将保存真实的目标函数对象（called）。

第二行语句表示artQuickResolutionTrampoline函数的返回值是called的入口地址。

所以当artQuickResolutionTrampoline成功返回后，art_quick_resolution_trampoline首先会判断r0的值是否为0。如果答案是否定的，那么紧接着就把r0赋值给r12，并从sp栈顶加载真实目标对象到r0，然后跳转到入口地址（r12）；否则就跳转到art_quick_resolution_trampoline中的exception进行异常处理。

这样Art虚拟机就成功地执行了字节码被编译生成的本地机器码了。

21.12 Android x86版本兼容ARM二进制代码——Native Bridge

目前手机等终端设备使用ARM芯片的居多，但这并不代表Android系统只能运用在一种硬件平台之上。事实上，Android系统本身是希望可以在更多的芯片平台上运行的，而且这种愿景也被越来越多的芯片厂商所支持——其中就包括Intel的x86架构。

Android x86版本至少在如下几个场景中具有应用价值：

- 终端设备

不管是手机、平板或是智能家居，均有不少厂商已经在x86架构上实现了Android产品。

- PC和笔记本电脑

PC上运行Android系统并不是什么新鲜事了，而且已经有几个开源组织在专门从事这方面的工作。大家如果有兴趣的话可以搜索了解详情。

- Android x86模拟器

Android模拟器长期以来广受诟病的缺陷就是“巨慢无比”。这其中的一个重要原因就是ARM版本的Android系统需要经过“翻译”才能运行于普遍采用x86架构的研发机器之上。换句话说，假如我们可以直接为开发人员提供x86版本的模拟器镜像，那么无疑可以极大地提高模拟器的性能，从而满足开发人员的工作需求。根据笔者和Intel员工的交谈得知，他们和Google在x86版本上开展过紧密的合作，其输出成果就是目前越来越好用的SDK中的x86模拟器了。

愿景总是很美好的，但Android x86版本如果希望在市面上得到广泛应用，有一个核心问题是必须要解决的——那就是如何在x86版本中兼容ARM二进制代码。

可能有如下两种方案可以解决上述这一问题：

方案1. 让各应用程序厂商在提供ARM库的同时，一并打包提供x86库

这个方案理论上讲可以很好地解决问题，而且Google为此也给开发者提供了很多便利——比如NDK就已经支持将源码同时编译成针对多个芯片架构的机器码。但是话说回来，并不是所有应用程序厂商都愿意承担这种额外的工作；同时，添加新的库文件也意味着APK体积的增长，这也是我们需要考虑的问题。

方案2. 在我们没有办法保证所有厂商都从“APK源头”来配合解决问题的情况下，如何从Android系统层面来提高对ARM二进制代码的兼容性就成了“必然的选择”。

这种方案也有几种实现方式，包括但不限于：

- Intel Houdini

Intel为了提高自己的芯片销量，在较早时期就开始思考并解决与ARM库的兼容性问题。可惜的是Intel并没有将这一成果作为开源项目贡献给Android社区，而是只将这一技术授权给采用Intel芯片的设备厂商。Intel考虑问题通常是从硬件芯片的销量角度出发，它并不关心软件本身所带来的直接价值（例如将Houdini作为技术方案收取费用）。不过因为芯片销售是Intel的业务主航道，所以它的这种做法本身倒是无可厚非的。

- Qemu User Mode

另一种在Android x86平台中兼容ARM的实现方式是利用Qemu User Mode。我们知道，Qemu有两个主要的工作模式，即Sysytem Mode和User Mode。前者表示用Qemu来模拟一个完整的“硬件平台”，包括CPU、内存及外围设备等；后者的例子则包括了著名的Wine——它的主要职责就是以一种轻量级的方式让Windows应用程序可以运行于POSIX-Compliant的操作系统之上。

- Native Bridge

从Android 5.0开始，Google官方提供了一个名为Native Bridge的中间模块，以支撑不同机器平台在运行非对应平台代码之间的问题（如

x86平台需要运行arm代码，就需要转换过程）。由于兼容性问题的解决是和具体硬件芯片相关联的，所以Native Bridge只能是起到“框架”的作用。而具体填充什么内容，则由芯片厂商（例如Intel）来完成

本小节我们将重点分析NativeBridge和houdini结合方案的部分实现原理。其中NativeBridge的实现主体在/system/core/libnativebridge中，只有一个native_bridge.cc文件。

那么NativeBridge具体会在程序运行中的什么时候起作用呢？

我们知道，Java层的代码如果要能顺利调用到native函数，首先得保证这个函数所在的library已经被成功加载到内存中。通常情况下，开发人员会使用System. LoadLibrary()来预先把一个so库加载到内存中。这个函数只是起到一个中转作用，它又会通过Java层的loadLibrary来进一步判断是否需要加载库。如果答案是肯定的话，那么程序会利用doLoad来完成具体的加载过程。后者将通过nativeLoad来简单调用一个已经利用well_known_classes.cc完成init的本地层C++函数Runtime_nativeLoad：

```
/*libcore/luni/src/main/java/java/lang/Runtime.java*/
static jstring Runtime_nativeLoad(JNIEnv* env, jclass, jstring ja
                             jobject javaLoader, jstring javaLdLi
  ScopedUtfChars filename(env, javaFilename);
  …
  SetLdLibraryPath(env, javaLdLibraryPathJstr);

  std::string error_msg;
  {
    JavaVMExt* vm = Runtime::Current()->GetJavaVM();
bool success = vm->LoadNativeLibrary(env, filename.c_str(), javaL
                                                &error_msg);
    …
  }
  env->ExceptionClear();
  return env->NewStringUTF(error_msg.c_str());
}
```

其中javaLdLibraryPathJstr有点类似于Linux中的LD_LIBRARY_PATH环境变量，它用于指示library的搜索路径。这个路径

是保证后续动态库可以成功加载的关键：

```
/*art/runtime/java_vm_ext.cc*/
bool JavaVMExt::LoadNativeLibrary(JNIEnv* env, const std::string&
class_loader, std::string* error_msg) {…
  SharedLibrary* library;
  Thread* self = Thread::Current();
  {
    // TODO: move the locking (and more of this logic) into Libra
    MutexLock mu(self, *Locks::jni_libraries_lock_);
    library = libraries_->Get(path);//首先判断是否已经加载过这个librar
  }
  if (library != nullptr) {//已经加载过的情况
    …
    return true;
  }

  Locks::mutator_lock_->AssertNotHeld(self);
  const char* path_str = path.empty() ? nullptr : path.c_str();
  void* handle = dlopen(path_str, RTLD_NOW);//打开library文件
  bool needs_native_bridge = false;//是否需要native bridge
  if (handle == nullptr) {//正常途径打开library失败
    if (android::NativeBridgeIsSupported(path_str)) {//当前不一定支
      handle = android::NativeBridgeLoadLibrary(path_str, RTLD_NO

      needs_native_bridge = true;
    }
  }
  …
  bool created_library = false;
  {//创建一个Shared Library
    std::unique_ptr<SharedLibrary> new_library(
        new SharedLibrary(env, self, path, handle, class_loader))
    MutexLock mu(self, *Locks::jni_libraries_lock_);
    library = libraries_->Get(path);//有lock的保护，以处理好多线程情况
    if (library == nullptr) {//为nullptr说明其他线程还没有完成对librar
      library = new_library.release();
      libraries_->Put(path, library);
      created_library = true;
    }
  }
  …
  bool was_successful = false;
  void* sym;
  if (needs_native_bridge) {
    library->SetNeedsNativeBridge();
    sym = library->FindSymbolWithNativeBridge("JNI_OnLoad", nullp
```

```
  } else {
    sym = dlsym(handle, "JNI_OnLoad");
  }
  if (sym == nullptr) {
    VLOG(jni) << "[No JNI_OnLoad found in \"" << path << "\"]";
    was_successful = true;
  } else {…
  }

  library->SetResult(was_successful);
  return was_successful;
}
```

LoadNativeLibrary的目的用一句话来简单概况，就是加载目标库并执行它的入口函数。通常JNI_OnLoad就是jni库的入口函数，开发人员会利用它来完成一些初始化操作。不过这个函数倒不是必须要存在的，所以即便是最终找不到JNI_OnLoad，也并不代表一定是出现程序异常了（此时会有log打印出来，作为warning）。加载目标库的过程基本上分为两条途径，即正常加载和借助native bridge加载的情况。换句话说，我们首先利用dlopen来尝试打开目标library，假如成功的话，那么接下来就可以走正常渠道；否则通过NativeBridgeIsSupported进一步判断是否支持native bridge，假如答案是肯定的话才会利用native bridge加载所需的动态链接库，具体使用的函数是NativeBridgeLoadLibrary。

接下来需要创建一个新的SharedLibrary。可以看到我们实际上是先new了一个SharedLibrary，然后再去竞争libraries lock——这是为了避免多个线程情况下，可能出现其他线程也需要加载同一个library的竞争环境。假如最后的结果显示library == nullptr，那么表明我们是第1个加载library的，此时就需要将library存储到libraries_中。

接下来的操作分为两种可能性。如果needs_native_bridge为true，表明当前出现了目标库与平台不兼容性的情况，解决的办法就是利用library->FindSymbolWithNativeBridge来查找到JNI_OnLoad；否则就是普通的情况，此时只需要通过dlsym就可以较容易地定位到目标函数JNI_OnLoad了。

上述的分析中，我们还需要对NativeBridgeIsSupported和FindSymbolWithNativeBridge做更深入的解析。其中NativeBridgeIsSupported本身的实现很简单：

```
bool NativeBridgeIsSupported(const char* libpath) {
  if (NativeBridgeInitialized()) {
    return callbacks->isSupported(libpath);
  }
  return false;
}
```

在native bridge已经初始化的情况下，通过callbacks提供的isSupported来得到结果。那么callbacks是什么呢？为了让大家有一个全局的认识，我们可以从native bridge的初始化过程入手来进行讲解。

Native bridge的生命周期包括5个状态，即：

```
enum class NativeBridgeState {
  kNotSetup,                      // 最初始的状态
  kOpened,                        // dlopen native bridge后转移到这个
  kPreInitialized,                // pre-initialization成功后转移到这个
  kInitialized,                   // 初始化成功后转移到这个状态
  kClosed                         // 发生错误或关闭native bridge后转移到
};
```

接下来的讲解就按照native bridge在各个状态间的迁移展开。

我们知道，Android应用程序是由Zygote孵化出来的，而后者又是寄居于AndroidRuntime之上的。当AndroidRuntime在启动一个虚拟机时，它同时也会对native bridge执行相关的配置，如下所示：

```
/*frameworks/base/core/jni/AndroidRuntime.cpp*/
int AndroidRuntime::startVm(JavaVM** pJavaVM, JNIEnv** pEnv,
{…
  property_get("ro.dalvik.vm.native.bridge", propBuf, "");
if (propBuf[0] == '\0') {
    ALOGW("ro.dalvik.vm.native.bridge is not expected to be e
} else if (strcmp(propBuf, "0") != 0) {
    snprintf(nativeBridgeLibrary, sizeof("-XX:NativeBridge=")
             + PROPERTY_VALUE_MAX,"-XX:NativeBridge=%s", prop
    addOption(nativeBridgeLibrary);
}
```

简单来讲，系统变量“ro.dalvik.vm.native.bridge”是native bridge的“开关”。即如果它不为0，那么就表示这个变量用于存储native bridge library对应的名称；否则就表示当前不需要启用

native bridge。AndroidRuntime中所做的这一配置会通过“-XX:NativeBridge=”传递给虚拟机，以便后者在初始化的时候应用起来：

```
bool Runtime::Init(const RuntimeOptions& raw_options, bool ignore
    std::string native_bridge_file_name =
                                runtime_options.ReleaseOrDefault(Op
    is_native_bridge_loaded_ = LoadNativeBridge(native_bridge_fil
```

其中native_bridge_library_filename就用于指示native bridge对应的so库的路径，它最开始就是由AndroidRuntime::startVm赋值的。真正去加载Native bridge的地方在LoadNativeBridge中：

```
/*art/runtime/native_bridge_art_interface.cc*/
bool LoadNativeBridge(std::string& native_bridge_library_filename
  return android::LoadNativeBridge(native_bridge_library_filename
                            &native_bridge_art_callbacks_);
}
```

需要注意的是，Art虚拟机代码中存在两个LoadNativeBridge函数，上面所示的代码段是其中的第1个，它起到“interface”的作用，以此来屏蔽不同虚拟机之间的差异。上述函数中的native_bridge_art_callbacks_代表了Art虚拟机相对于native bridge的回调接口，它是一个NativeBridgeRuntimeCallbacks结构体，如下所示：

```
static android::NativeBridgeRuntimeCallbacks native_bridge_art_ca
  GetMethodShorty, GetNativeMethodCount, GetNativeMethods
};
```

第2个LoadNativeBridge会根据上一个函数传递的参数来加载具体的native bridge library，核心代码如下：

```
/*system/core/libnativebridge/native_bridge.cc*/
bool LoadNativeBridge(const char* nb_library_filename,
                  const NativeBridgeRuntimeCallbacks* runtime_cbs
  if (nb_library_filename == nullptr || *nb_library_filename == 0
    CloseNativeBridge(false);
    return false;
  } else {
    if (!NativeBridgeNameAcceptable(nb_library_filename)) {
      CloseNativeBridge(true);
    } else {
```

```
      // Try to open the library.
      void* handle = dlopen(nb_library_filename, RTLD_LAZY);//打开
      if (handle != nullptr) {
        callbacks = reinterpret_cast<NativeBridgeCallbacks*>(dlsy
                                                      kNativeBridgeIn
        if (callbacks != nullptr) {
          if (VersionCheck(callbacks)) {
            native_bridge_handle = handle;
          } else {…
          }
        } else {
          dlclose(handle);
        }
      }
      if (callbacks == nullptr) {
        CloseNativeBridge(true);
      } else {
        runtime_callbacks = runtime_cbs;//保存与runtime之间的通信接口
        state = NativeBridgeState::kOpened;//状态迁移
      }
    }
    return state == NativeBridgeState::kOpened;
  }
}
```

当我们在实现类似函数时，首先应该思考的是上述这个函数是否需要lock的保护？我们知道，当程序执行到这里时还没有创建其他线程。意味着并不存在多线程竞争的环境，所以在LoadNativeBridge中还不需要锁保护。

LoadNativeBridge的处理逻辑并不复杂，因而我们不对细节部分做过多分析。它的主要任务就是按照nb_library_filename打开native bridge的动态实现库，然后dlsym找到名为kNativeBridgeInterfaceSymbol的符号。kNativeBridgeInterfaceSymbol是一个字符串，被赋值为“NativeBridgeItf”（这个名字猜测可能是NativeBridgeInterface的简写），换句话说native bridge library必须要暴露一个NativeBridgeItf接口。而至于native bridge library的具体名称，则由“ro.dalvik.vm.native.bridge”来决定。所以说任何基于native bridge的实现（如houdini）都需要配置这个系统属性。

至此native bridge就加载成功了，不过流程还没有结束，因为我们在使用它之前还需要先做初始化。那么什么时候执行初始化呢?这个

时机当然应该是在应用程序的虚拟机正式工作前。具体而言，是由Zygote孵化器来控制的。我们在本书的系统启动章节对Zygote有详细的描述，如果有需要大家可以结合起来阅读。在native bridge这个场景中，我们只需要补充两点知识：

- 当有一个Android新应用程序需要启动时，Zygote会介入处理，并调用forkAndSpecialize。
- 当fork结束时，callPostForkChildHooks会被调用。

函数forkAndSpecialize以及它所调用的其他函数的作用是在Zygote中fork出一个子进程，并通过一系列改造将其转变为目标应用程序。另外，这些工作的主体并非在Java层，而是在native层，所涉及的最核心的一个jni函数是nativeForkAndSpecialize，后者又会进一步调用ForkAndSpecializeCommon：

```
/*frameworks/base/core/jni/com_android_internal_os_Zygote.cpp*/
static pid_t ForkAndSpecializeCommon(…) {…
    bool use_native_bridge = !is_system_server && (instructionSet
        && android::NativeBridgeAvailable();//是否需要使用native br
    if (use_native_bridge) {
      ScopedUtfChars isa_string(env, instructionSet);
      use_native_bridge = android::NeedsNativeBridge(isa_string.c
    }
    if (use_native_bridge && dataDir == NULL) {…
      use_native_bridge = false;
      ALOGW("Native bridge will not be used because dataDir == NU
    }
    …
    if (use_native_bridge) {
      ScopedUtfChars isa_string(env, instructionSet);
      ScopedUtfChars data_dir(env, dataDir);
      android::PreInitializeNativeBridge(data_dir.c_str(), isa_st
    }
…
    env->CallStaticVoidMethod(gZygoteClass, gCallPostForkChildHoo
                          is_system_server ? NULL : instructionSet
    …
  } else if (pid > 0) {
  }
  return pid;
}
```

是否zygote fork出来的所有进程都需要native bridge呢？不一

定。譬如当前是system server（系统类的进程都是针对硬件平台编译出来的，不会出现这种问题），或者native bridge不可用（此时说明系统中没有开启这个功能，或者是功能不可用），或者data路径为空等情况下就无需native bridge。另外，即便上述条件都满足，但当前进程并不存在兼容性问题（比如当前是x86平台，而且动态链接库也是针对x86编译的），那么当然也不需要native bridge。

如果确定必须使用native bridge，那么还应该对它进行pre-initialize，即：

```
/*system/core/libnativebridge/native_bridge.cc*/
bool PreInitializeNativeBridge(const char* app_data_dir_in, const
instruction_set) {...
  const size_t len = strlen(app_data_dir_in) + strlen(kCodeCacheD
  app_code_cache_dir = new char[len];
  snprintf(app_code_cache_dir, len, "%s/%s", app_data_dir_in, kCo
  state = NativeBridgeState::kPreInitialized;//状态迁移

#ifndef \_\_APPLE__
  if (instruction_set == nullptr) {
    return true;
  }
  size_t isa_len = strlen(instruction_set);
  …
  char cpuinfo_path[1024];

#ifdef HAVE_ANDROID_OS
  snprintf(cpuinfo_path, sizeof(cpuinfo_path), "/system/lib"
#ifdef __LP64__
      "64"
#endif  // __LP64__
      "/%s/cpuinfo", instruction_set);
#else   // !HAVE_ANDROID_OS
  // To be able to test on the host, we hardwire a relative path.
  snprintf(cpuinfo_path, sizeof(cpuinfo_path), "./cpuinfo");
#endif

  // Bind-mount.
  if (TEMP_FAILURE_RETRY(mount(cpuinfo_path,        // Source.
                               "/proc/cpuinfo",     // Target.
                               nullptr,             // FS type.
                               MS_BIND,             // Mount flag
                               nullptr)) == -1) {   // "Data."
    ALOGW("Failed to bind-mount %s as /proc/cpuinfo: %s", cpuinfo
  }
```

```
#else  // __APPLE__
  UNUSED(instruction_set);
  ALOGW("Mac OS does not support bind-mounting. Host simulation o
#endif

  return true;
}
```

不难发现，pre-initialize时还未与真正的native bridge（如houdini）产生关系，而是虚拟机本身为native bridge的运行而所做的一系列准备工作。真正初始化native bridge实现体的地方在Runtime::Start中，进一步讲是Start调用的InitNonZygoteOrPostFork函数中。因为在我们这个场景下action为NativeBridgeAction::kInitialize，所以InitNonZygoteOrPostFork内部会根据这一action的值来执行InitializeNativeBridge，从而完成对native bridge的初始化。

接下来我们再回答另一个问题，即NativeBridgeLoadLibrary是如何通过native bridge来加载目标对象的：

```
/*system/core/libnativebridge/native_bridge.cc*/
void* NativeBridgeLoadLibrary(const char* libpath, int flag) {
  if (NativeBridgeInitialized()) {
    return callbacks->loadLibrary(libpath, flag);
  }
  return nullptr;
}
```

不难发现，系统直接调用了native bridge实现体所提供的callbacks->loadLibrary，而最终如何完成对目标库的加载则由native bridge的实现体厂商（如Intel提供的houdini）来全权负责。因为houdini并不是开源项目，无法直接对其内部实现展开阐述。不过网上已经有不少利用特殊手段对其进行分析的资料，有兴趣的读者可以搜索阅读，如图21-69所示。

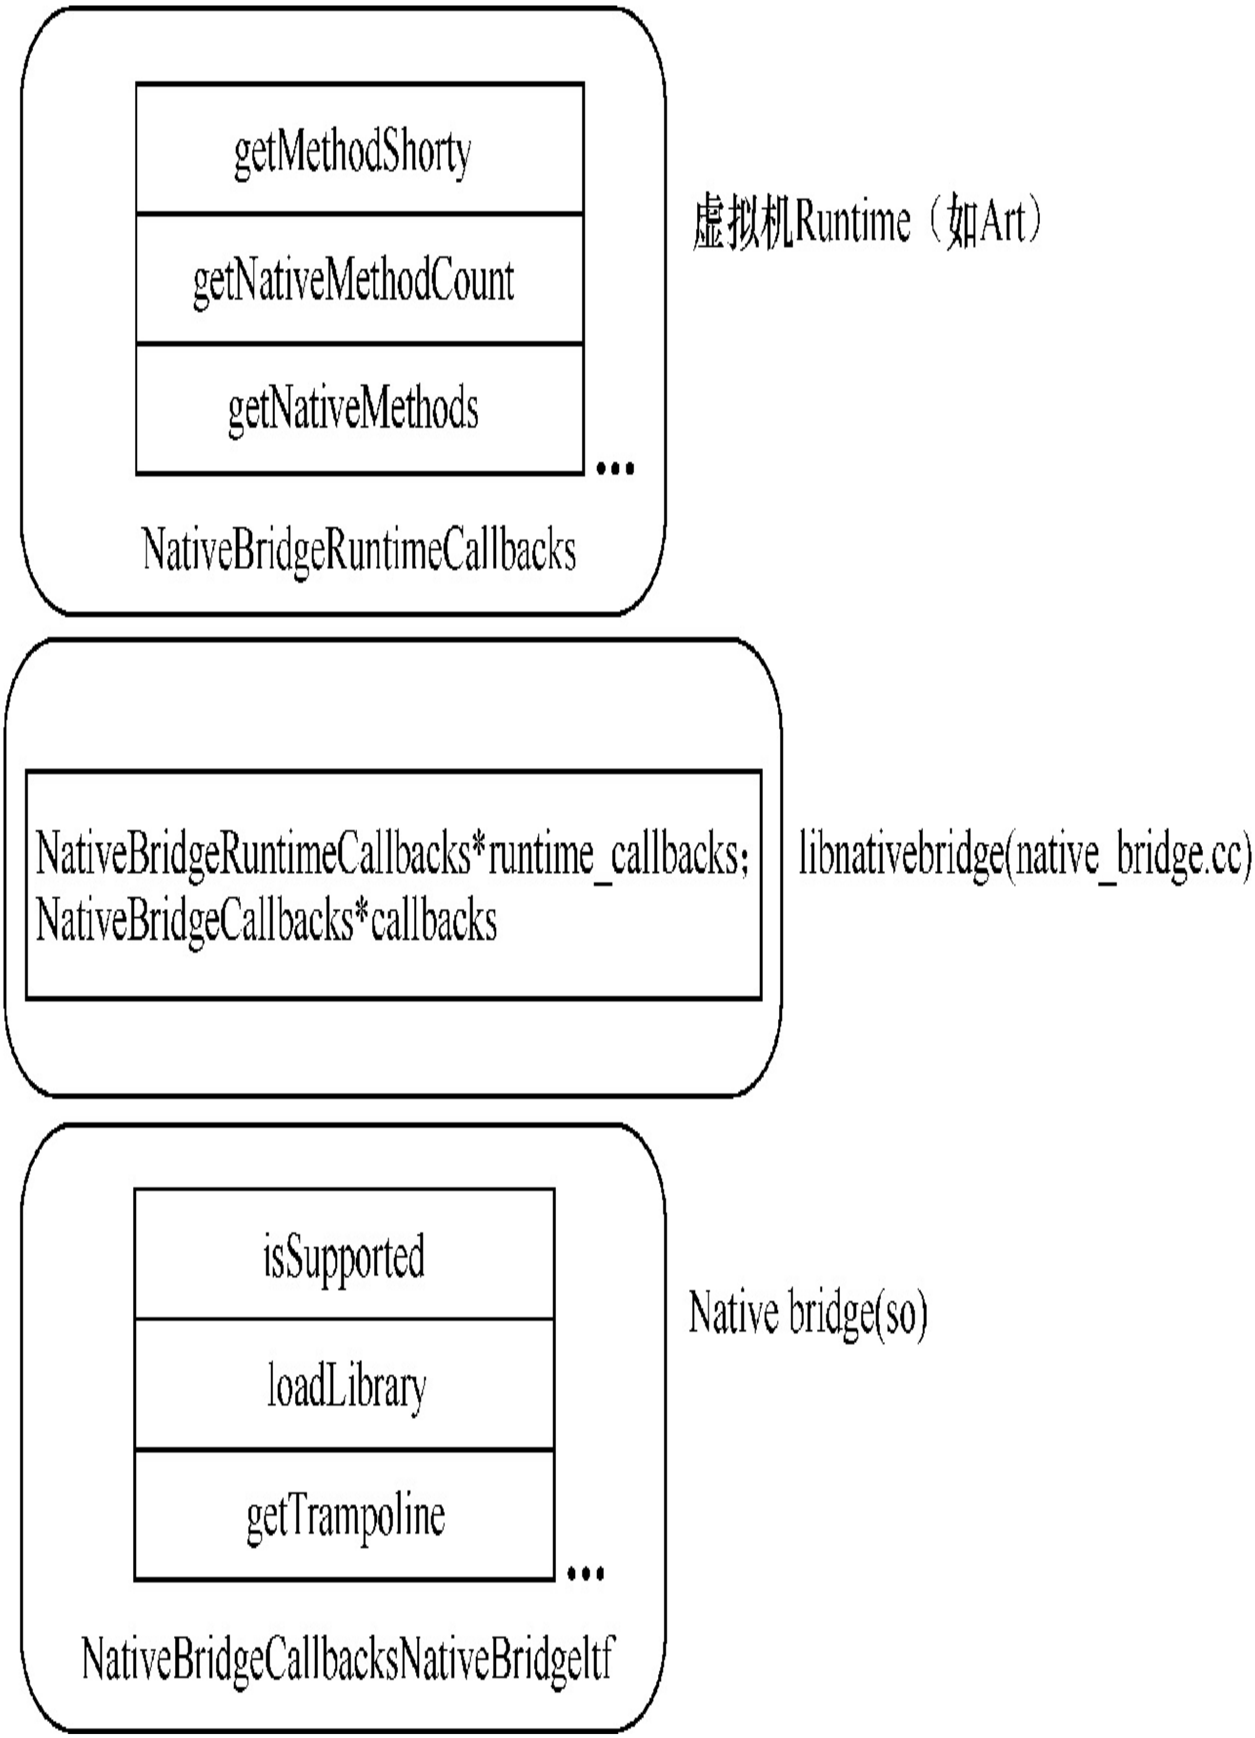
getMethodShorty
getNativeMethodCount
getNativeMethods
...
NativeBridgeRuntimeCallbacks
虚拟机Runtime（如Art）
NativeBridgeRuntimeCallbacks*runtime_callbacks;
NativeBridgeCallbacks*callbacks
libnativebridge(native_bridge.cc)
isSupported
loadLibrary
getTrampoline
...
NativeBridgeCallbacksNativeBridgeItf
Native bridge(so)

▲图21-69　Library之间的关系

最后我们再来小结一下本小节出现的3个library之间的关系。

- Native bridge的具体实现会被封装在一个so库中

如果用户没有通过“-XX:NativeBridge=”特别指定的话，那么so库的名字就使用默认值。另外，native bridge的so库需要expose一个名为“NativeBridgeItf”的接口，对应的是NativeBridge Callbacks结构体，其中实现了isSupported、loadLibrary等关键函数。值得一提的是，系统中允许多个native bridge的存在

- libnativebridge只是一个中介，它所提供的callback函数在内部又会调用真正的native bridge库的实现（如Intel提供的houdini library）。
- jni库

这是需要被native bridge处理的目标对象。在我们本小节的分析范围内，特指需要在x86平台上运行的ARM动态链接库

21.13　Android应用程序调试原理解析

调试是应用程序开发过程中不可或缺的一个环节，相信读者们都不会陌生。得益于各类IDE工具（如Eclipse、IntelliJ等）的辅助，开发人员调试Android应用程序可以说是相当简单的。以Android Studio为例，调试Java代码的步骤如下：

Step1. 在Android Studio中打开你的工程；

Step2. 在需要调试的地方打上断点；

Step3. 单击Debug按钮；

Step4. 选择需要运行应用程序的目标设备（Optional）；

Step5. 开始调试。

效果如图21-70所示。

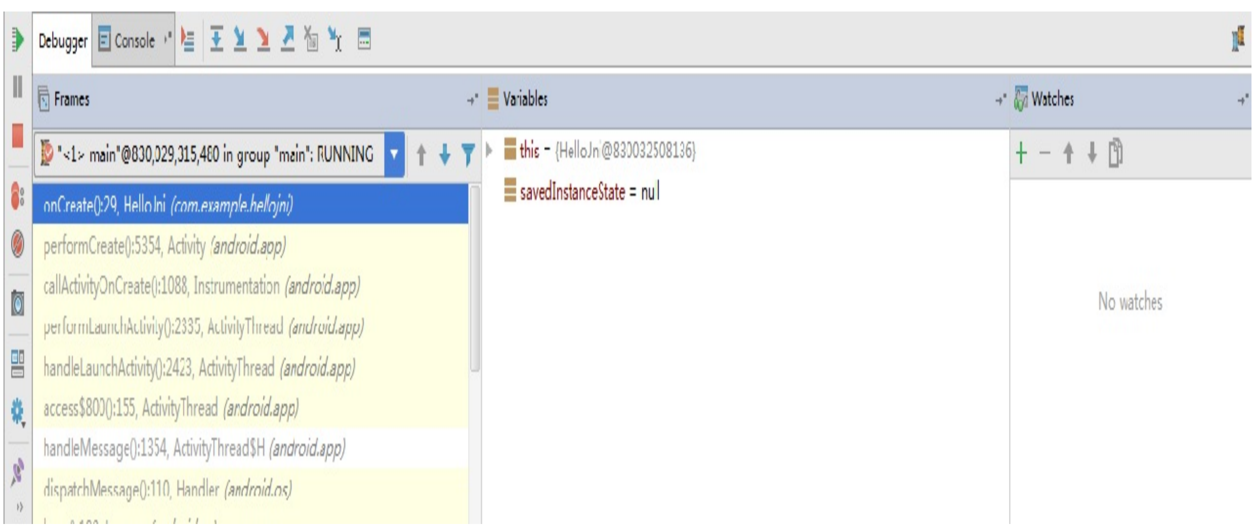

▲图21-70　Android应用程序调试效果

当然，这看似简单的几个步骤背后隐藏的技术细节却是很复杂的。我们将在本小节对此展开分析。

21.13.1　Java代码调试与JDWP协议

JDWP，即Java Debug Wire Protocol，是被调试的目标Java程序与调试器之间的一种协议规范，在Java世界中被广泛应用。它在Android中的主体框架如图21-71所示。

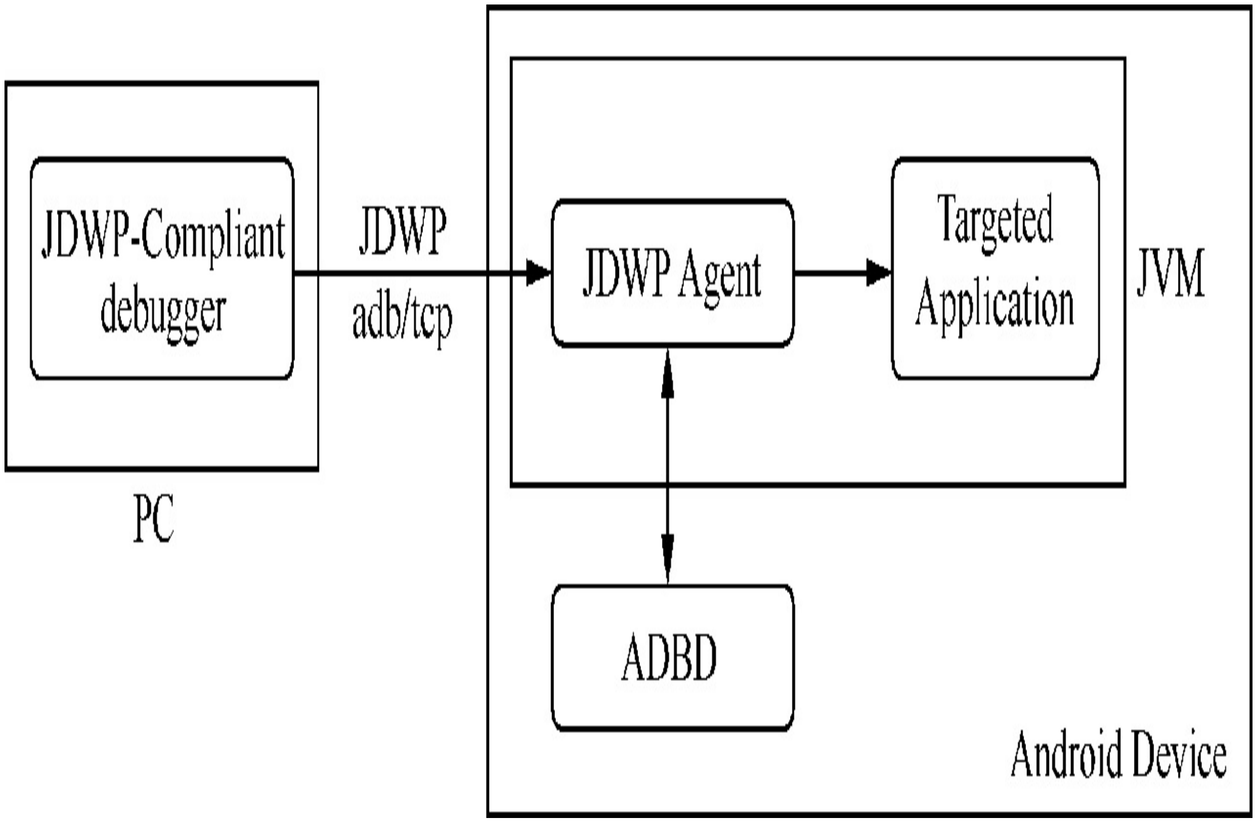

▲图21-71　Java调试原理简图

在以JDWP为基础的调试器方案中，主要会涉及如下几个角色（以Android虚拟机为例）：

- JDWP-Compliant Debugger

调试器通常运行于PC端，它会借助于JDWP Agent来控制运行于设备端的目标程序。我们知道，开发机与设备的连接既有可能是TCP/IP的方式（如模拟器），也有可能是USB等硬件连接线的方式。在我们接下来的分析中，主要侧重后面这种情况。

- JDWP Agent

Agent和目标程序一样，都运行于设备端的虚拟机中，并且与调试

器之间以JDWP规范进行数据传输。

- 目标程序

目标程序即是调试对象，它受JDWP Agent的控制，而后者则接受来自Debugger Client的指令。

- ADBD

即ADB Daemon。它是ADB在设备端的监护程序，负责开发平台与设备之间的通信，调试过程也同样需要ADBD。

下面我们以一个典型的Android平台上Java程序的调试过程为范例来做细化讲解。

Step1@Android平台Java程序的调试过程——ADBD初始化阶段

当ADBD启动的时候，它会创建一个名为“\0jdwp-control”的Unix Server Socket，这是万里长征的第一步。如果一个Java程序需要被调试的话，那么虚拟机会启动一个新的JDWP的Daemon线程，后者将负责与“\0jdwp-control”建立连接。这个连接会一直保持活跃状态，直到JDWP进程终止。

因为调试的进程有可能不止一个，所以ADBD内部维护着当前活跃的JDWP进程的一个列表。ADBD可以通过“device:debug-ports”和它们进行通信。从源码的角度来分析，ADBD会在adb_main中调用init_jdwp来完成对jdwp的初始化动作：

```
/*/system/core/adb/jdwp_service.cpp*/
int init_jdwp(void)
{
    _jdwp_list.next = &_jdwp_list;
    _jdwp_list.prev = &_jdwp_list;
    …
    return jdwp_control_init( &_jdwp_control, JDWP_CONTROL_NAME,
                             JDWP_CONTROL_NAME_LEN );
}
```

其中_jdwp_list是当前可调试进程的存储列表；JDWP_CONTROL_NAME对应的是“\0jdwp- control”。另外，

jdwp_control_init负责创建一个AF_UNIX类型的socket，并监听来自JDWP Agent的连接请求。

Step2@Android平台Java程序的调试过程。被调试的目标Android应用工程，将通过如下命令来启动：

```
am start -D -n "com.example.hellojni/com.example.hellojni.HelloJn
intent.action.MAIN -c android.intent.category.LAUNCHER
```

这里的“-D”参数是一个关键点，它表示我们希望开启应用程序的调试状态。以这种状态启动的App在启动过程中会主动等待来自Debugger的Attach请求。

Step3@Android平台Java程序的调试过程. 在Art虚拟机中，当应用程序启动后，会由Runtime在DidForkFromZygote中负责启动一个JDWP线程，如下所示：

```
/*art/runtime/runtime.cc*/
void Runtime::DidForkFromZygote(JNIEnv* env, NativeBridgeAction a
  …
  Dbg::StartJdwp();
}
```

Runtime使用专门的管理类Dbg来支持Debugger功能。Dbg内部维护着一个名为gJdwpState的全局JdwpState变量，后者用于记录JDWP的当前状态：

```
/*art/runtime/Debugger.cc*/
void Dbg::StartJdwp() {
  if (!gJdwpAllowed || !IsJdwpConfigured()) {//程序当前是否符合调试条
    // No JDWP for you!
    return;
  }
…
  gJdwpState = JDWP::JdwpState::Create(&gJdwpOptions);
  …
}
```

当前程序如果要进入调试环境，需要同时满足下面两个条件：

- gJdwpAllowed

这个变量用于表示Zygote是否允许调试。又可以分为如下两种情况：

Case1：系统变量ro.debuggable为1，这种情况下表示所有的程序都可以被调试，因而在量产的设备中是不允许的。

Case2：当系统请求Zygote孵化一个新进程时，可以通过“--enable-debugger”来显式地要求后者将目标进程置为可调试状态。这个请求的原始来源就是AndroidManifest中的android:debuggable配置，Android系统在ActivityManagerService中会对此进行处理，相应代码段如下所示：

```
/*frameworks/base/services/core/java/com/android/server/am/Activi
private final void startProcessLocked(ProcessRecord app, String h
  hostingNameStr, String abiOverride, String entryPoint, String[]
            if ((app.info.flags & ApplicationInfo.FLAG_DEBUGGABLE
                debugFlags |= Zygote.DEBUG_ENABLE_DEBUGGER;
                // Also turn on CheckJNI for debuggable apps. It'
                // awkward to turn on otherwise.
                debugFlags |= Zygote.DEBUG_ENABLE_CHECKJNI;
            }
         …
```

- IsJdwpConfigured返回结果为真

这个函数用于查询jdwp是否已经配置完成。正常情况下，runtime会在初始化时通过Dbg::ConfigureJdwp来执行jdwp的配置工作。

只有上述两个条件都满足的情况下，Dbg才会创建一个JdwpState变量。下面我们再分析一下JDWP::JdwpState::Create这个函数，并重点了解它是如何与Adb建立关联的：

```
/*art/runtime/jdwp/jdwp_main.cc*/
JdwpState* JdwpState::Create(const JdwpOptions* options) {
  Thread* self = Thread::Current();
  Locks::mutator_lock_->AssertNotHeld(self);
  std::unique_ptr<JdwpState> state(new JdwpState(options));
  switch (options->transport) {
    case kJdwpTransportSocket:
      InitSocketTransport(state.get(), options);
      break;
#ifdef HAVE_ANDROID_OS
```

```
    case kJdwpTransportAndroidAdb:
      InitAdbTransport(state.get(), options);
      break;
#endif
    default:
      LOG(FATAL) << "Unknown transport: " << options->transport;
  }

  {…
    CHECK_PTHREAD_CALL(pthread_create, (&state->pthread_, nullptr
                             state.get()),"JDWP thread");
    …
  }

  if (options->suspend) {/*suspend="y",意味着需要等待直到debugger成功
  接debugger成功后才允许程序继续往下运行*/
    {
      ScopedThreadStateChange tsc(self, kWaitingForDebuggerToAtta
      MutexLock attach_locker(self, state->attach_lock_);
      while (state->debug_thread_id_ == 0) {
        state->attach_cond_.Wait(self);
      }
    }
    …
  }

  return state.release();
}
```

在讲解上述这个函数之前，我们先来补充一些背景知识。

Android虚拟机和大部分的桌面型JVM一样，它们都提供了若干配置参数来允许用户对调试器进行调整。

Android虚拟机中的调试器支持的核心选项如表21-14所示。

表21-14　支持的核心选项

Options	Description
	Communication transport mechanism.支持以下两种类型：

transport	● TCP/IP Sockets即dt_socket。譬如模拟器通常情况下就是以TCP/IP的方式进行通信的 ● Over USB through ADB即dt_android_adb。开发机与Android真机设备以USB线连接后，可以通过ADB进行通信
server	默认值“n”这个选项指明虚拟机要以Client或者Server的方式运行。如果是后者，那么它会等待debugger发起的连接请求；Client的情况正好相反，它需要主动去连接debugger
suspend	默认值“n”简单来讲就是虚拟机在执行程序代码之前是否要进入挂起状态。如果设置为“y”，那么表明虚拟机在执行程序代码前会先处于挂起状态，以便等待来自debugger的连接（或者虚拟机主动完成与debugger的连接——取决于上面的server模式）
address	address代表虚拟机需要连接/或者监听的IP地址以及port号（只对dt_socket的情况下有效）。当server模式设置为“n”时，address的格式是hostname:port；当server模式设置为“y”时，address的格式可以是hostname:port，也可以只是port。如果port是0，代表当前将首先尝试在端口8000进行监听——如果失败的话，依次再尝试8001、8002等
help	用于显示Usage帮助信息
launch, onthrow, oncaught, timeout	这些选项目前会被虚拟机直接忽略掉

下面是一个Android虚拟机的配置范例：

```
-agentlib:jdwp=transport=dt_android_adb,suspend=y,server=y -cp /d
```

它代表虚拟机将开启debugging功能；并作为服务端来等待客户端的连接请求；同时连接通道采用的是adb。

我们再回过头来分析JdwpState::Create函数。首先需要根据transport类型的不同来完成两种情况下的初始化，即InitSocketTransport和InitAdbTransport。对于前一种情况，JdwpState中的成员变量netState将是一个JdwpSocketState对象；而如果是Adb Transport，则对应的是JdwpAdbState——这两种State的基类都是JdwpNetStateBase。根据表21-14中的描述，如果VM是Server的话，那么它的Port端口要么来源于用户的特别指定（保存在JdwpOptions中），要么从Port 8000开始尝试，直到最大值8040为止。

Create最重要的任务是启动一个新线程“JDWP Thread”，对应的处理函数是StartJdwpThread。如果options中指定了suspend=y,那么当前线程需要等待JDWP Thread完成与Debugger的通信连接后才能继续往下执行。因而当前线程会在attach_cond_上等待，而JDWP则需要在完成操作后主动发信号给它以解除等待。

StartJdwpThread将进一步调用JdwpState::Run来开展具体工作。而且对于adb这种情况，事实上采用的都是server=y的配置，因而完成与ADBD通信任务的载体函数是JdwpAdbState:: Accept。根据我们前面讲解的内容，不难推断出Accept将利用名为“\0jdwp-control”的Unix Socket与ADBD建立连接，并且在成功后发送当前进程ID给对方。下一个Step中我们将进一步分析ADBD如何处理VM的JDWP连接请求。

Step4@Android平台Java程序的调试过程. ADBD中响应JDWP连接请求的具体函数是jdwp_process_event。如果接收到的PID经过解析后确认格式无误的话，ADBD会通过jdwp_process_list_updated来更新自己维护的一个进程列表。紧接着程序分为两个方向：

- VM JDWP Thread

如果是suspend=y的情况，则一直等待直到完成与debugger的连接;否则应用程序继续执行代码。

- ADBD

ADBD是debugger和Jdwp Thread之间的“媒人”，它会响应来自debugger的请求，并为它们牵线搭桥

Step5@Android平台Java程序的调试过程。经过前面步骤的努力，此时已经是“万事具备，只欠东风”了——Debugger就是这阵东风。

运行于开发机之上的Debugger如果想连接到目标JVM中的Jdwp Thread，它首先需要使用如下命令：

```
adb forward tcp:<hostport> jdwp:<pid>
```

当adbd收到上述命令时，它将执行如下操作：

```
/*system/core/adb/services.cpp*/
int service_to_fd(const char *name)
{…
   } else if (!strncmp(name, "jdwp:", 5)) {
        ret = create_jdwp_connection_fd(atoi(name+5));
…
```

因为“jdwp:”属于特殊服务标志，所以ADB可以很容易地把它转发给Jdwp Service，后者对此的核心处理逻辑是：先从ADBD维护的_jdwp_list中查找到正确的JDWP Process，在此基础上调用adb_socketpair产生一对SocketPair。SocketPair是一种全双工的通信机制，可以保证通信双方的同时读和写操作。其中第1个Socket将与ADB的local socket进行绑定；而另一个socket则发送给JDWP Thread（此时正处于ReceiveClientFd的状态）。JDWP Thread在后续操作中就可以利用这个socket描述符和debugger建立直接的数据通信（包括JDWP-Handshake、彼此间的调试命令等）了。图21-72所示是对Socket连接关系的描述图。

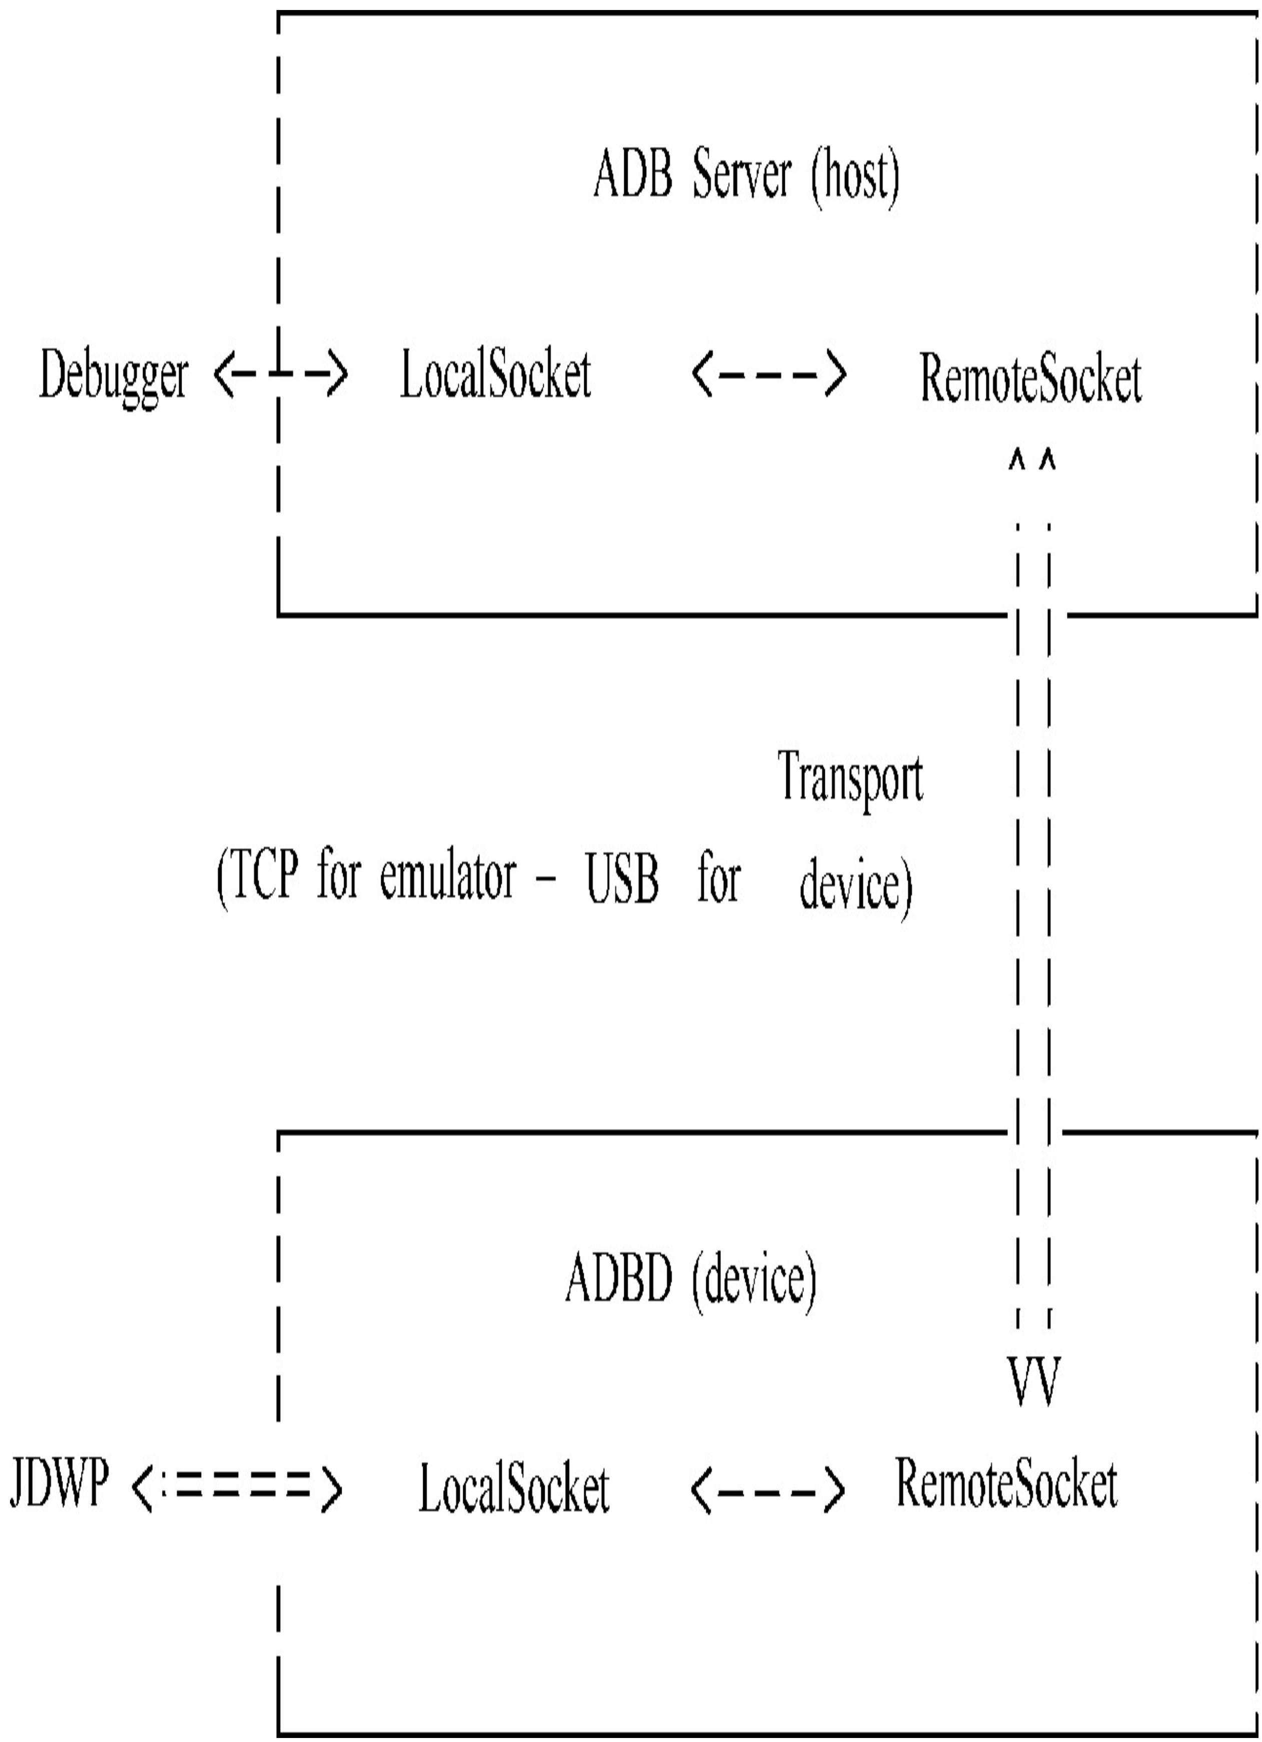

ADB Server (host)
Debugger
LocalSocket
RemoteSocket
Transport
(TCP for emulator - USB for device)
ADBD (device)
JDWP
LocalSocket
RemoteSocket

▲图21-72　ADB Transport下的Socket连接关系图

至此，位于开发机器上的Debugger就已经和运行于设备端JVM之中的JDWP Thread建立起关联了。假如是suspend=y的情况，JDWP需要主动发送信号给JVM主线程，以便后者（处于等待状态，此时UI界面上也会有相应提示）可以恢复运行。应用程序进入调试状态后，Debugger按照JDWP的严格约定向JDWP Thread发送命令，以控制程序执行单步、断点等调试操作。

接下来我们以单步调试为例子，进一步分析JDWP、Debugger和Art之间的关系。

图21-73所示是它们的关系简图。

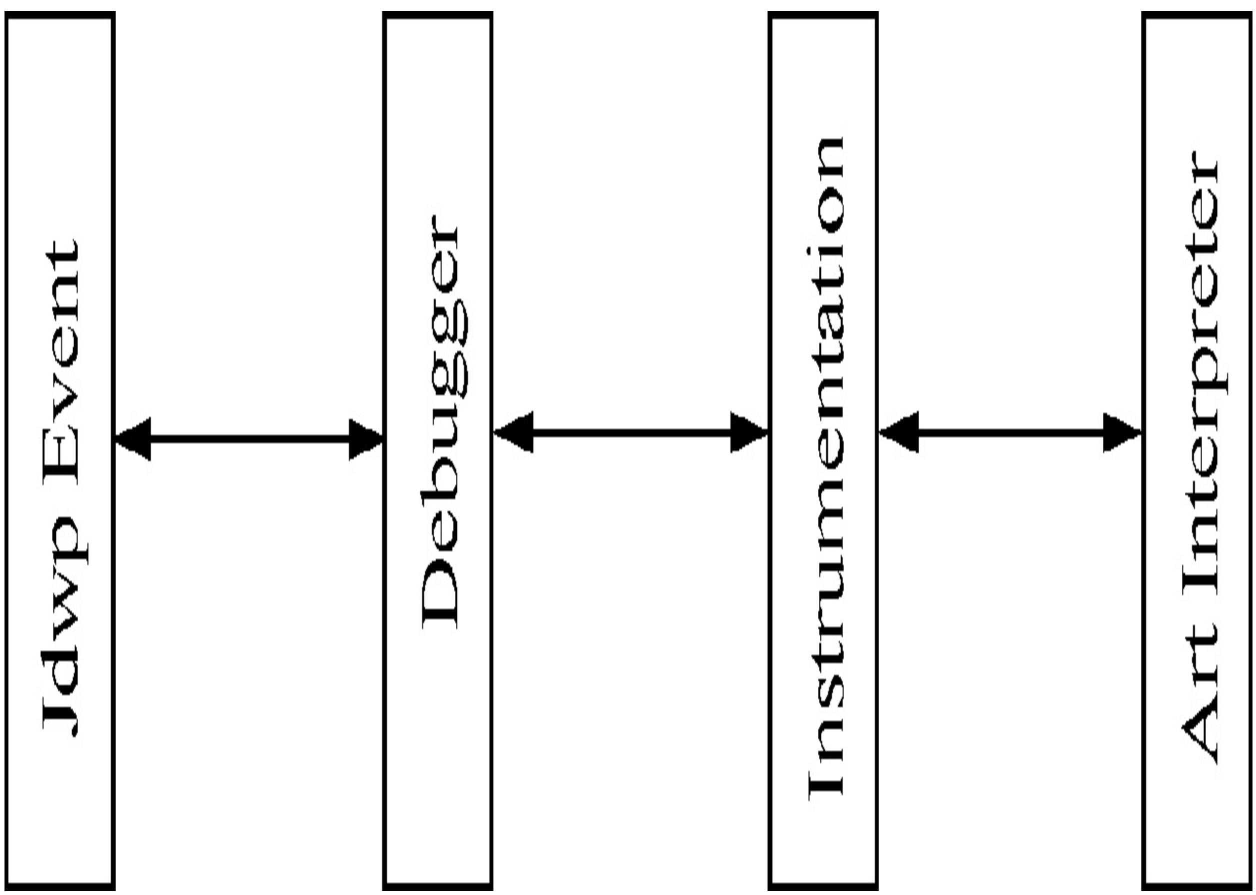

▲图21-73 关系图

要注意区分这里的Instrumentation和我们在做Android应用程序单

元测试时所使用的Instrumentation测试框架。后者用于“监控”Android系统与应用程序之间的通信，从而实现类似于白盒测试这种需要深入App内部来完成的任务。

图21-73中的Instrumentation有异曲同工之妙，只不过目标对象变成了Art虚拟机。Instrumentation提供了一个AddListener接口，意味着任何对虚拟机运行过程中相关数据感兴趣的模块都可以请求“监听”。譬如除了Debugger之外，另一个重要的Instrumentation应用就是Trace，它是SDK中Trace Viewer的实现基础：

```
/*art/runtime/Instrumentation.cc*/
void Instrumentation::AddListener(InstrumentationListener* listen
```

那么虚拟机都暴露了哪些信息给外界呢？这是通过上述AddListener的最后一个参数，即events来表达的：

```
  enum InstrumentationEvent {
    kMethodEntered = 0x1,    //函数进入
    kMethodExited = 0x2,     //函数退出
    kMethodUnwind = 0x4,     //
    kDexPcMoved = 0x8,       //PC指针发生了变化
    kFieldRead = 0x10,       //域读取
    kFieldWritten = 0x20,    //域写入
    kExceptionCaught = 0x40, //异常发生
    kBackwardBranch = 0x80,  //
  };
```

不难理解，Debugger的工作要涵盖3个方面：

- 初始化；
- 利用Instrumentation获取虚拟机的实时运行状态；
- 根据开发者的调试请求来控制虚拟机的执行情况。

针对单步调试的场景，Debugger在初始化过程中会创建一个JdwpState对象，用于管理与Jdwp协议相关的事情。同时，它也负责调用Instrumentation::AddListener来为自己添加感兴趣的InstrumentationEvent——譬如与单步调试相关联的kDexPcMoved。

调试过程中Art虚拟机需要运行于解释器模式下。Art中的Interpreter有两种实现类型（Android N版本中又增加了一种汇编解释

器），即kSwitchImpl和kComputedGotoImplKind。不过无论哪一种解释器，它在每执行一条字节码命令时都会调用类似如下的语句：

```
  if(UNLIKELY(instrumentation->HasDexPcListeners())) {
    instrumentation->DexPcMovedEvent(self,
                                  shadow_frame.GetThisObject(code_item-
                                      shadow_frame.GetMethod(),dex_pc);
  }
```

UNLIKELY是GCC提供的一个有趣的功能，用于提高CPU的执行效率。简单来说，为了使CPU的Pipeline尽可能处于满负荷的状态，我们可以设计让它提前加载下一条要执行的语句。但是在某些情况下，这种设计并没有起到应有的效果。例如一个if(condition)..else语句，在条件没有确定之前，我们并不能确定程序在运行时会走哪个分支，这样导致的结果就是CPU提前加载的语句很可能用不上。因而GCC提供了LIKELY和UNLIKELY等属性，这样开发人员可以“帮助”CPU来更精准地判断出应该提前加载的指令。

只要注册了Listener，那么HasDexPcListeners就会返回true。这种情况下会调用DexPcMoved Event，这个函数的主要工作是遍历Instrumentation中所有注册了的对象。Debugger中重载了DexPcMoved函数，后者的核心关键在于UpdateDebugger：

```
/*art/runtime/Debugger.cc*/
void Dbg::UpdateDebugger(Thread* thread, mirror::Object* this_obj
                   ArtMethod* m, uint32_t dex_pc,
                   int event_flags, const JValue* return_value) {
  …
  if (IsBreakpoint(m, dex_pc)) {//程序当前执行到断点了吗
    event_flags |= kBreakpoint;
  }

  const SingleStepControl* single_step_control = thread->GetSingl
  if (single_step_control != nullptr) {
    CHECK(!m->IsNative());
    if (single_step_control->GetStepDepth() == JDWP::SD_INTO) {…
    } else if (single_step_control->GetStepDepth() == JDWP::SD_OV
      int stack_depth = GetStackDepth(thread);//当前线程的函数栈

      if (stack_depth < single_step_control->GetStackDepth()) {
        // Popped up one or more frames, always trigger.
        event_flags |= kSingleStep;
        VLOG(jdwp) << "SS method pop";
```

```
      } else if (stack_depth == single_step_control->GetStackDept
        // Same depth, see if we moved.
        if (single_step_control->GetStepSize() == JDWP::SS_MIN) {
          event_flags |= kSingleStep;
          VLOG(jdwp) << "SS new instruction";
        } else if (single_step_control->ContainsDexPc(dex_pc)) {
          event_flags |= kSingleStep;
          VLOG(jdwp) << "SS new line";
        }
      }
    } else {
      CHECK_EQ(single_step_control->GetStepDepth(), JDWP::SD_OUT)
      …
    }
  }

  // If there's something interesting going on, see if it matches
  // of the debugger filters.
  if (event_flags != 0) {
    Dbg::PostLocationEvent(m, dex_pc, this_object, event_flags, r
  }
}
```

大家试想一下，开发人员在IDE（例如Android Studio、Eclipse）中调试程序时，通常会涉及哪些操作呢？

- 断点

  譬如打断点、取消断点、查看断点等。

- Step Into

  单步执行，而且会进入被调用的函数。

- Step Over

  单步执行，但不会进入被调用的函数。

- Step Out

  执行完本函数剩余的代码，并返回到调用者函数中。

  ……

开发人员在IDE中所做的上述操作，都会通过Jdwp协议实时发送给设备端，并由后者做好记录。对于单步调试来说，开发者的不少请求是由Thread（单步调试是针对某个线程环境执行的，因而是线程相关的）内部的一个SingleStepControl对象来负责管理，外界可以通过GetSingleStepControl访问它。

有了这些背景我们理解UpdateDebugger就简单多了。这个函数的核心思想就是判断程序是否已经执行到了某个我们“感兴趣”的关键点，包括开发者设置的BreakPoint,开发者StepInto、StepOver、StepOut命令所对应的目标位置等。针对3种Step操作的处理过程是类似的，我们结合StepOver来讲解一下上述UpdateDebugger函数的代码逻辑：如果当前的函数堆栈深度小于原先的深度，说明程序已经从子函数中返回来了，因而event_flags会被设置为kSingleStep；否则，如果两者堆栈深度一样，那么有可能是StepOver，即它们的代码行数发生了变化。一旦这些“兴趣点”被发掘出来，程序会调用PostLocationEvent来做进一步处理。这个函数的核心工作有两个，其一是向Jdwp的另一方（比如IDE）发送消息，告知对方最新的状态；其二是根据Suspend Policy来判断当前是否需要挂起所有（或者部分）虚拟机线程。

这样一来整个调试过程——PC端和设备端的连接、JDWP的基本原理，断点/单步操作的双方交互等内容就讲解完成了。不过JDWP是一个相对成熟的调试协议，其中还包含了很多其他细节。建议读者可以自行查阅Java官方发布的JDWP规范，并结合Android虚拟机的具体实现来做更深入的分析。

21.13.2 Native代码调试

Android系统既支持Java语言，同时也允许开发者使用C/C++等Native语言来编写程序。所以开发人员不可避免地需要一个基于Native语言的调试环境。

随着Android放弃Eclipse ADT，转而投向基于IntelliJ的Android Studio的怀抱，越来越多的开发者开始采用这一新工具来开展项目。客观来讲，Android Studio相对于它的“前辈们”确实有其特色所在。但它毕竟还“太年轻”，在不少方面还不够“成熟稳定”。譬如针对Native代码的调试，Android Studio虽然在最新的版本中已经支持，但仍在不断改进中。Android Studio对此也并不避讳，在其界面上会有如下提示：

> NDK support is an experimental feature and all use cases are not yet supported.

所有与NDK相关的功能都仍处于实验阶段——这或许也是不少开发者反映Android Studio“坑”很多的原因。

即便如此，Android的NDK调试机制还是有不少地方值得大家学习。接下来我们先通过NDK的典型调试流程来让读者对如何利用Android Studio调试Native代码有一个直观的认识（注：调试Native代码有很多种选择，这里所示的只是其中一种，大家可以根据实际项目需求选择最佳的方案）。

Step1. 新建Android Application工程；

Step2. 添加JNI源文件，以及其他C/C++文件。

在Android Studio中添加C/C++文件有很多种途径。在早期版本中，开发者需要先手工生成Class文件，再利用javah生成C/C++的头文件，然后才能编辑源代码。这种手工配置的方式既繁琐又浪费时间——Android Studio显然也意识到了这点，所以它正尝试利用Gradle来为开发者提供更为便捷的实现方式。

可能是因为上述这项功能还处于实验阶段，所以事实上Gradle配置起来也很麻烦。具体过程大家可以参考官方的详细介绍：

http://tools.android.com/tech-docs/new-build-system/gradle-experi

配置完Gradle之后，接下来我们就可以创建JNI目录了，如图21-74所示。

然后在jni目录下创建C/C++源文件，示例如图21-75所示。

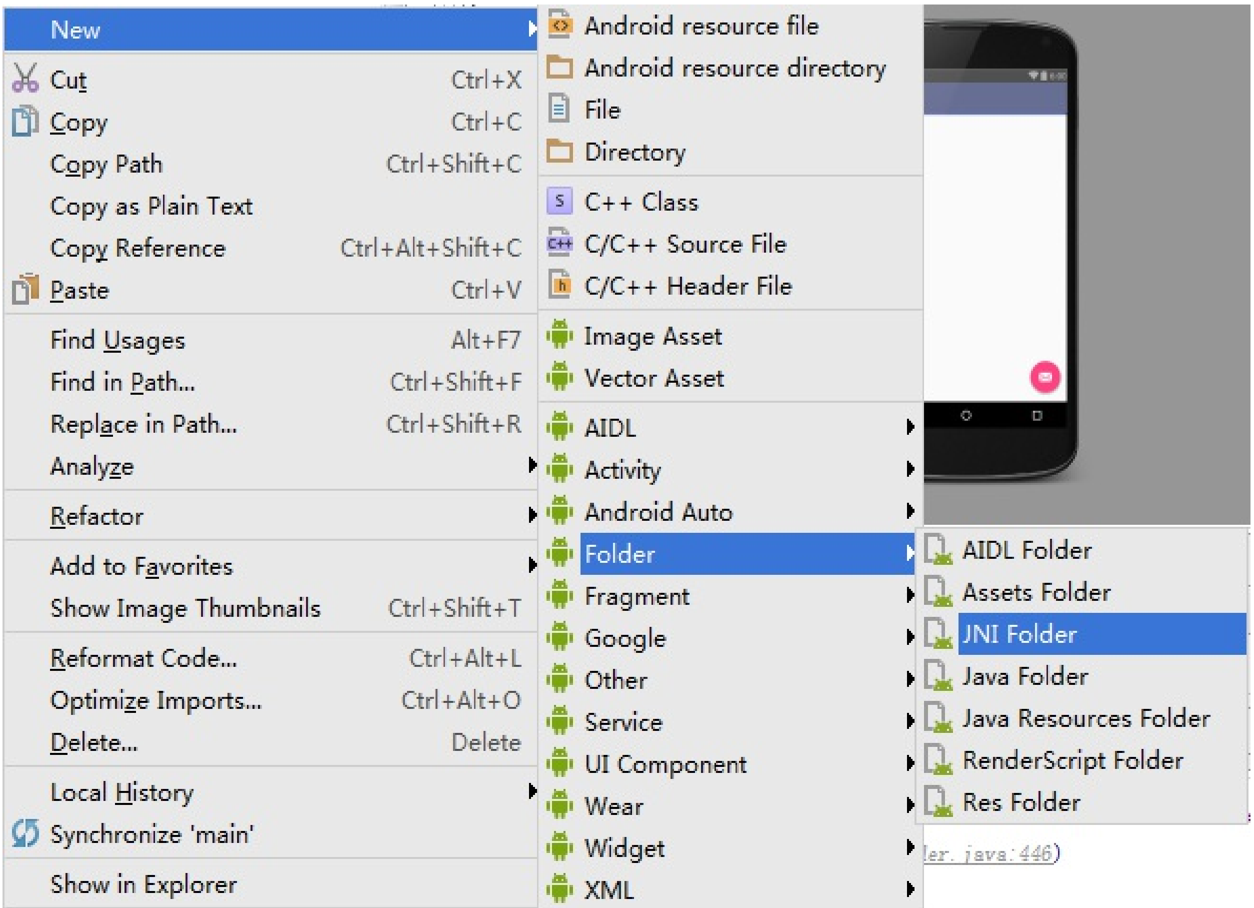

New
Cut Ctrl+X
Copy Ctrl+C
Copy Path Ctrl+Shift+C
Copy as Plain Text
Copy Reference Ctrl+Alt+Shift+C
Paste Ctrl+V
Find Usages Alt+F7
Find in Path... Ctrl+Shift+F
Replace in Path... Ctrl+Shift+R
Analyze
Refactor
Add to Favorites
Show Image Thumbnails Ctrl+Shift+T
Reformat Code... Ctrl+Alt+L
Optimize Imports... Ctrl+Alt+O
Delete... Delete
Local History
Synchronize 'main'
Show in Explorer
Android resource file
Android resource directory
File
Directory
C++ Class
C/C++ Source File
C/C++ Header File
Image Asset
Vector Asset
AIDL
Activity
Android Auto
Folder
Fragment
Google
Other
Service
UI Component
Wear
Widget
XML
AIDL Folder
Assets Folder
JNI Folder
Java Folder
Java Resources Folder
RenderScript Folder
Res Folder

▲图21-74 JNI目录

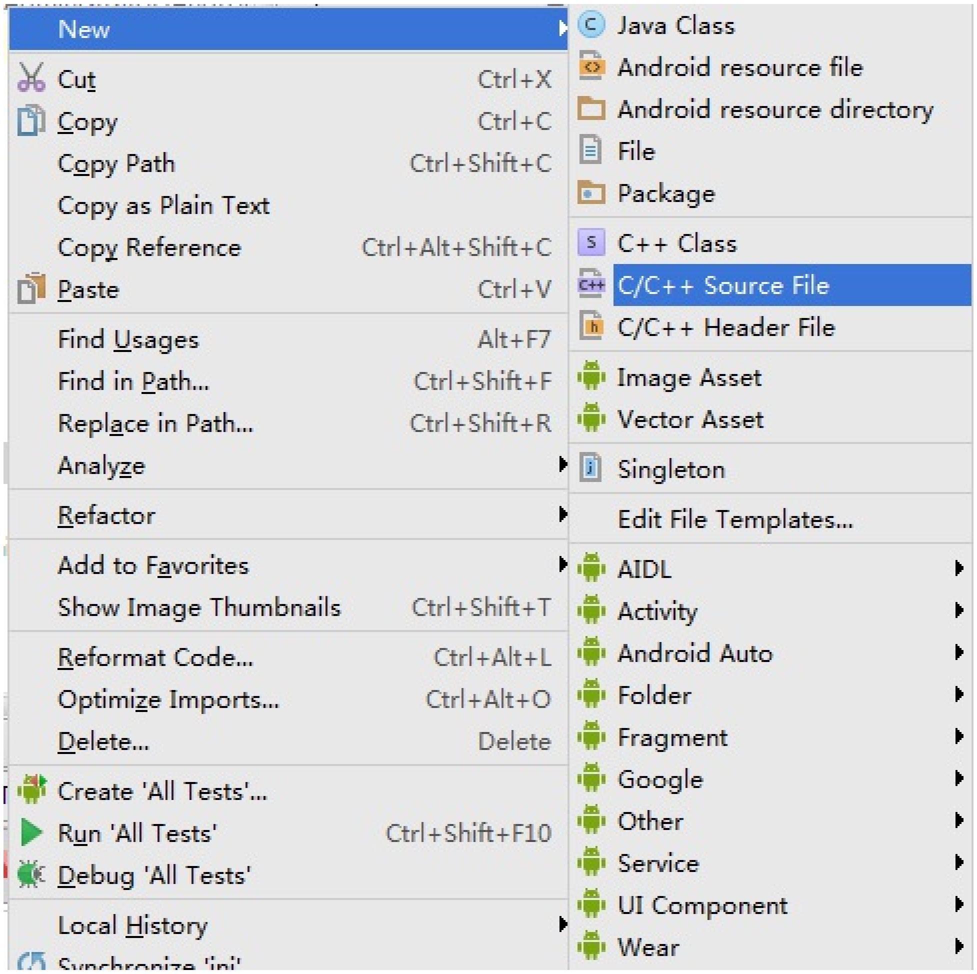

▲图21-75　示例

完成上述这些工作后，我们就可以根据项目的具体需要来添加和编写C/C++代码了。如果希望运行代码的话，直接使用Android Studio的Run功能就可以了；如果想调试代码，还需要做一下Android Native方面的配置，示例如图21-76所示。

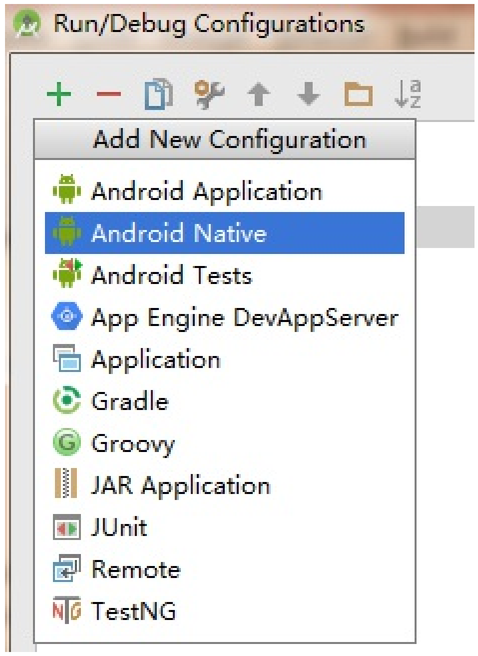

▲图21-76 配置

最终的调试效果如图21-77所示。

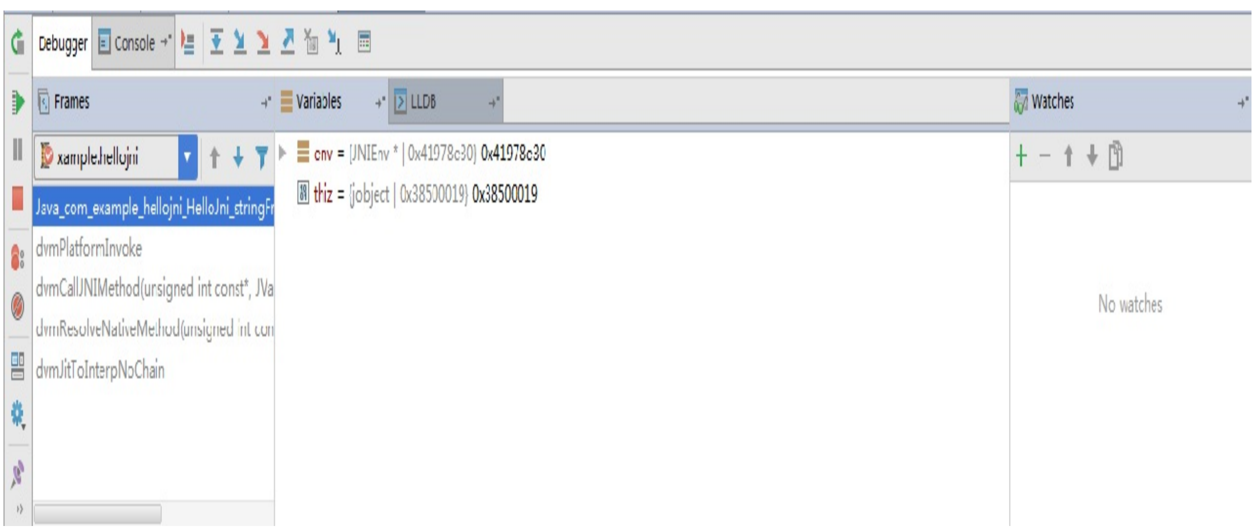

▲图21-77 Android Native应用程序调试效果

了解了Native程序的典型调试流程后，我们再来分析上述过程中所涉及的内部原理。

Android Studio中同时支持两种C/C++调试器，即GDB和LLDB。不过

无论是哪种调试器，它们的基本原理是类似的。所以我们选取LLDB这个新型的调试器为例来做细化讲解。

通过LLDB调试Android Native Application的原理简图如图21-78所示。

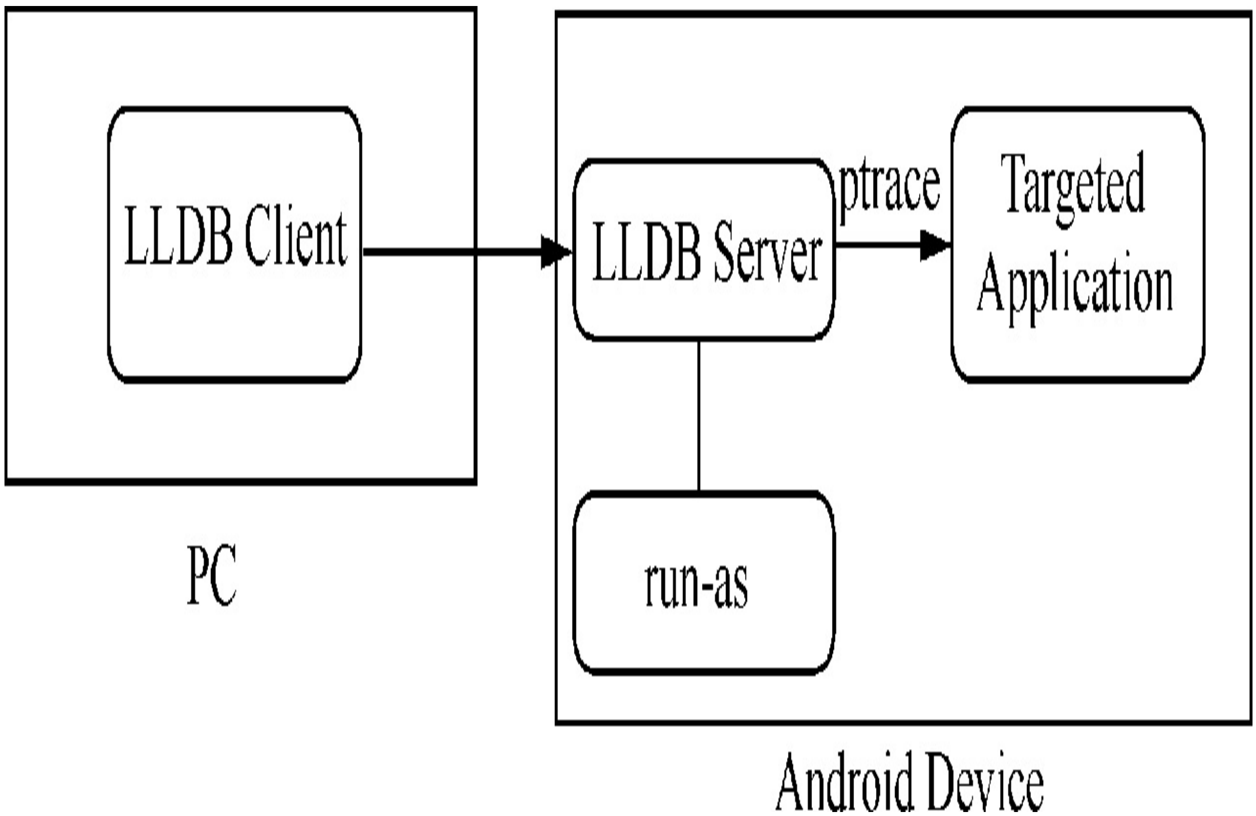

▲图21-78　Android Native Debug

我们可以从Android Studio输出的Log中，得出整个调试环节将涉及的所有adb命令，从中就可以窥探出交互过程了：

```
##命令行1:
DEVICE SHELL COMMAND: am force-stop com.example.hellojni
Launching application: com.example.hellojni/com.example.hellojni.

###命令行2:
DEVICE SHELL COMMAND: am start -D -n
"com.example.hellojni/com.example.hellojni.HelloJni" -a android.i
###命令行3:
DEVICE SHELL COMMAND: run-as com.example.hellojni mkdir /data/dat
###命令行4:
```

```
DEVICE SHELL COMMAND: run-as com.example.hellojni mkdir /data/dat
bin
###命令行5:
DEVICE SHELL COMMAND: cat /data/local/tmp/lldb-server | run-as co
data/com.example.hellojni/lldb/bin/lldb-server'
Starting: Intent { act=android.intent.action.MAIN cat=[android.in

###命令行6:
DEVICE SHELL COMMAND: cat /data/local/tmp/start_lldb_server.sh |
700 /data/data/com.example.hellojni/lldb/bin/start_lldb_server.sh

###命令行7:
Starting LLDB server: run-as com.example.hellojni /data/data/com.
example.hellojni/lldb/tmp/platform-1454849510931.sock "lldb proce
Now Launching Native Debug Session
Debugger attached to process 5186
```

从上述可以看到，整个过程涉及的命令种类和数量都不少。我们接下来对它们逐一进行讲解。

命令行1：

```
DEVICE SHELL COMMAND: am force-stop com.example.hellojni
Launching application: com.example.hellojni/com.example.hellojni.
```

命令行2：

```
DEVICE SHELL COMMAND: am start -D -n
"com.example.hellojni/com.example.hellojni.HelloJni" -a android.i
```

上述这两条命令比较简单，它们的任务是通过/system/bin/am这个shell脚本来启动目标进程HelloJni的Main Activity。

而第3条命令行就没有那么好理解了：

```
DEVICE SHELL COMMAND: run-as com.example.hellojni mkdir /data/dat
```

主要的疑问如下：

- run-as是什么？
- /data/data/com.example.hellojni/lldb是hellojni的私有目录，那么shell为什么有权限创建它呢？

我们知道，Linux平台上的调试系统普遍借助于ptrace来实现。但是一个不容忽视的问题是—— ptrace并非“等闲之辈”，它需要特殊的权限才能被正常使用。那么gdb（或者LLDB）在没有root的手机上如何跨越这个障碍呢？

总体来说，有如下几种备选方案：

Solution1：将调试所用的手机做root处理

这不但是最“笨”的一种办法，而且也显得有些“旁门左道”，所以绝对不会是Android所推崇的最佳方式。

Solution2：让GdbServer与被调试程序运行于同一个进程中

由于Android系统对于两个程序运行于同一个进程之中有严格的门槛限制，所以这也不会是我们的首选方式。

Solution3：找一个有权限的“中介”帮忙搞定这个事

这就好比我们想在一个高档小区找人，无奈身为访客没有权限随意进出。怎么办呢？大家的第一反应可能是找门卫。一方面门卫是小区对外的“接口”，访客是可以接触到的；另一方面他们也有正常的渠道可以联系到业主。这样一来问题就简单了：只要我们能提供足够的信息证明自己“并不是坏人”，而且与小区业主确实是“有关系”的，那么就可以请门卫代为传话，最终也就可以达到让“目标业主”现身的目的了。

程序run-as的作用和“门卫”有点类似。它的权限位设置如图21-79所示。

```
1|shell@hwmt7:/ $ ls -l /system/bin/run-as
-rwxr-x--- root     shell      9440 2016-01-21 21:21 run-as
```

▲图21-79　run-as是Native调试成功的关键点之一

由图21-79可见，run-as的Owner虽然是root，但所属的群组却是shell。这样设计的目的就是让我们（adb shell）有权限（shell对应的权限位是“r-x”）来调用这个“门卫”，从而保证后续操作的顺利开展。从“run-as”这个名字也可以看出，它表达的是让对象A在运行

时具有和对象B相同的某种属性。

那么具体是指哪些属性呢？下面是run-as的使用语法：

```
run-as <package-name> [--user <uid>] <command> [<args>]
```

其中<package-name>代表对象B的包名；<command>代表对象A；<args>则表示run-as所需的各种参数。

那么run-as是借助了什么“魔法棒”来让对象A“脱胎换骨”呢？

事实上它的实现原理并没有那么复杂，简单而言就是run-as会迫使<command>所指示的对象A以对象B的User ID来运行。核心代码实现如下所示：

```
/*system/core/run-as/run-as.c*/
int main(int argc, char **argv)
{
    const char* pkgname;
    uid_t myuid, uid, gid, userAppId = 0;
    int commandArgvOfs = 2, userId = 0;
    PackageInfo info;
    struct __user_cap_header_struct capheader;
    struct __user_cap_data_struct capdata[2];
    …
    /* 调用run-as的必须是shell或者root，以避免它被滥用的情况*/
    myuid = getuid();
    if (myuid != AID_SHELL && myuid != AID_ROOT) {
        panic("only 'shell' or 'root' users can run this program\
    }

    memset(&capheader, 0, sizeof(capheader));
    memset(&capdata, 0, sizeof(capdata));
    capheader.version = _LINUX_CAPABILITY_VERSION_3;
    capdata[CAP_TO_INDEX(CAP_SETUID)].effective |= CAP_TO_MASK(CA
    capdata[CAP_TO_INDEX(CAP_SETGID)].effective |= CAP_TO_MASK(CA
    capdata[CAP_TO_INDEX(CAP_SETUID)].permitted |= CAP_TO_MASK(CA
    capdata[CAP_TO_INDEX(CAP_SETGID)].permitted |= CAP_TO_MASK(CA

    /*赋予run-as自身SUID和SGID的权利*/
    if (capset(&capheader, &capdata[0]) < 0) {
        panic("Could not set capabilities: %s\n", strerror(errno)
    }
    pkgname = argv[1];//对象B的包名
```

```
    /* 处理用户通过“—user”主动提供了user id的情况*/
    if ((argc >= 4) && !strcmp(argv[2], "--user")) {
        userId = atoi(argv[3]);
        if (userId < 0)
            panic("Negative user id %d is provided\n", userId);
        commandArgvOfs += 2;
    }

    /* 根据包名获取到相对应的userId */
    if (get_package_info(pkgname, userId, &info) < 0) {
        panic("Package '%s' is unknown\n", pkgname);
    }
    …
    /* calculate user app ID. */
    userAppId = (AID_USER * userId) + info.uid;

    /* 对象B不能是system package */
    if (userAppId < AID_APP) {
        panic("Package '%s' is not an application\n", pkgname);
    }

    /* 对象B必须已经设置了可调试标志位 */
    if (!info.isDebuggable) {
        panic("Package '%s' is not debuggable\n", pkgname);
    }

    /* 检查data路径是否有效 */
    if (check_data_path(info.dataDir, userAppId) < 0) {
        panic("Package '%s' has corrupt installation\n", pkgname)
    }

    uid = gid = userAppId;
    if(setresgid(gid,gid,gid) || setresuid(uid,uid,uid)) {
        panic("Permission denied\n");
    }//通过setresgid和setresuid保证run-as具有setuid和setgid的权利，这

    …
    /* cd进入对象B的data目录下*/
    if (TEMP_FAILURE_RETRY(chdir(info.dataDir)) < 0) {
        panic("Could not cd to package's data directory: %s\n", s
    }

    /*运行对象A，此时对象A已经具有对象B的User Id了*/
    if ((argc >= commandArgvOfs + 1) &&
        (execvp(argv[commandArgvOfs], argv+commandArgvOfs) < 0))
        panic("exec failed for %s: %s\n", argv[commandArgvOfs], s
}
```

```
    /* Default exec shell. */
    execlp("/system/bin/sh", "sh", NULL);

    panic("exec failed: %s\n", strerror(errno));
}
```

从上述代码段的注释中，读者们应该已经发现了如下几个实现要点。

- run-as的权限控制

为了防止run-as被滥用，我们需要对用户身份进行验证。换句话说，就是只有shell和root才有资格使用这个特殊的程序；另外，目标对象B不可以是System Package，而且必须设置了debug标志位——对于Android应用程序来说，也就是应该在AndroidManifest.xml中显式声明了android:debuggable=true。

- run-as需要具备setuid和setgid的权限

我们在本书安全机制章节中会对Linux平台下的各权限位做较为详细的分析，希望大家可以结合起来阅读。与Linux中passwd作法不同的是，run-as并没有给文件本身直接设置SUID和SGID权限位，而是在它运行时再通过调用capset来改变自己的capacity。一旦capset成功后，run-as就有权限利用setresuid和setresgid来设置uid和gid为目标对象B的User ID和Group ID了。

- run-as通过exec系列API来调用目标对象A

一旦run-as的当前UID和GID已经被设置为目标对象B后，它会进一步利用execvp和execlp等API来加载和运行对象A。

经过这3个方面的努力后，对象A在运行时就具有目标对象B的UID了。在命令行3这个场景中，就是mkdir以hellojni的UID运行后，得以创建后者的私人目录/data/data/com.example.hellojni/lldb。命令行4到命令行6的原理也是类似的，我们就不赘述了。

命令行7：

```
run-as com.example.hellojni
/data/data/com.example.hellojni/lldb/bin/start_lldb_server.sh /da
```

在这个命令中，对象A对应的是start_lldb_server.sh，目标对象B是指com.example.hellojni，而后面几个是args参数。Android Studio在执行调试之前，会首先将一些文件push到设备的临时存储空间中，如下所示：

```
shell@HM2014501:/data/local/tmp $ ls
com.example.hellojni
lldb-server
start_lldb_server.sh
```

其中start_lldb_server.sh的核心实现如下：

```
#!/system/bin/sh

LLDB_DIR=$1 ###LLDB的工作目录是/data/data/com.example.hellojni/lldb
BIN_DIR=$LLDB_DIR/bin

LOG_DIR=$LLDB_DIR/log
TMP_DIR=$LLDB_DIR/tmp

export LLDB_DEBUGSERVER_LOG_FILE=$LOG_DIR/gdb-server.log
export LLDB_SERVER_LOG_CHANNELS="$3"
export LLDB_DEBUGSERVER_DOMAINSOCKET_DIR=$TMP_DIR

rm -r $TMP_DIR
mkdir $TMP_DIR
export TMPDIR=$TMP_DIR

rm -r $LOG_DIR
mkdir $LOG_DIR

cd $TMP_DIR # change cwd

# Send SIGTERM for all spawned processes.
#trap "kill 0" SIGINT SIGTERM EXIT

# lldb-server platform exits after debug session has complet
$BIN_DIR/lldb-server platform --listen $2 --log-file $LOG_DIR/pla
```

这个脚本的最后一行负责启动lldb-server，并在platform-1454849510931.sock端口上监听事件，保证后续调试操作的顺利进行。这样PC端（通常是IDE）和设备端就通过LLDB（或者GDB）建立起关联了，接下来它们只需要按照规定的调试协议来互相通信就可以了。

当然，关于lldb-server还有很多实现细节，譬如它是如何与IDE配合执行单步调试命令的；如何将程序当前正在执行的指令与源代码行数实现无缝对接的；如何控制目标对象的执行逻辑的等。有兴趣的读者可以自行分析AOSP工程中/external/lldb里的源码了解详情。

21.13.3 利用GDB调试Android Art虚拟机

相信不少开发者遇到过Art虚拟机或者Android系统服务崩溃的情况。虽然系统会为此打印出一个BackTrace，但从实践经验来看光靠这些信息想解决问题可以说是“大海捞针”。那么我们是否还有更好的办法来解决Art虚拟机或者Android自身服务的Bug呢？答案是肯定的，那就是利用调试手段来跟踪系统的内部实现。

前两个小节我们所讲解的调试是针对应用程序的，其中Jdwp适用于Java语言，而GDB（和LLDB）则被认为是Native Code的调试利器。再往深层次思考一下，既然GDB可以调试本地代码，而且是基于ptrace这类Linux提供的能力，那么理论上是不是也适用于Android系统服务（不光是Art虚拟机，还包括Zygote、ServiceManager等）呢？

本小节我们就来验证上述这个观点是否正确。

事实上系统程序的调试原理和上一小节所述的内容是基本类似的，区别在于应用程序是在IDE（或者其他开发环境）中发起的调试过程，这为开发人员节省了很多手工的操作。

以调试Art虚拟机为例，典型步骤如下：

Step1. 准备好所需的调试器程序和文件。包括：GDB Client、GDB Server、Symbols、目标程序等。GDB本身也是一个开源的项目，开发者如果有兴趣的话可以自行下载并编译出它的可执行文件。我们这里直接采用Android系统工程中提供的全套GDB工具，所在目录是:

AndroidRoot\prebuilts\gcc\linux-x86

开发人员需要根据被调试对象所属的具体平台来选择对应的子文件夹，譬如arm、x86等。

Step2. 将GDB Server推送到设备端

如果是Android模拟器，那么在设备的/system/bin目录下已经保存了gdbserver；而对于已经上市的Android设备，多数情况下这个Server端程序已经被移除了，此时我们需要将它手工推送到设备端

Step3. 利用ps命令查找需要调用的目标程序的PID值

值得一提的是，GDB既支持对已经在运行的程序进行调试，同时也可以主动启动一个被调试程序的进程实例——这就意味着它可以控制和调试目标进程的启动过程。

我们本小节想要调试的对象是Art虚拟机，并且知道它是以libart.so的形式存在的，而加载Art库的进程即是应用程序本身。或者更确切的说，是app_process（因为所有应用程序都是由Zygote孵化出来的，而后者则又是基于app_process产生的）。

例如我们可以选取前述小节的求和小程序为调试对象，如下所示：

```
shell@hwmt7:/ $ps
u0_a272   21143 3671  1574624 48976 ffffffff 00000000 S com.examp
```

即PID值是21143

Step4. 通过GDB Server来Attach目标进程

我们这个例子中采用Attach的方式来控制目标对象，所使用的命令如下：

```
gdbserver :1234 --attach [PID]
```

成功Attach上以后，gdbserver会显示如下信息：

```
# Listening on port 1234
```

Step5. 将Target设备的端口映射到开发机上

这个步骤是保证GDB Client可以顺利连接上Server的关键。所使用的命令范例如下：

```
adb forward tcp:1234 tcp:1234
```

Step6. 现在是“万事俱备，只欠东风”了，这阵风毫无疑问就是Host机上的GDB Client。我们首先要做的就是让它与Server端建立连接，命令范例如下：

```
arm-eabi-gdb ##启动GDB客户端
file out/target/[platform]/symbols/system/bin/app_process ##选择目
target remote :1234 ##与Server建立连接
```

此时GDB连接已经成功建立起来了，只不过在调试过程中还无法与源代码对应起来。为了解决这个问题，我们还需要为目标程序设置带有调试信息的库文件。范例命令如下所示：

```
set solib-absolute-prefix /out/target/product/[XX]/symbols
set solib-search-path /out/target/product/[XX]/symbols/system/lib
```

一切准备就绪。接下来我们就可以使用GDB提供的一系列命令进行各种调试操作了，譬如b（设置断点）、s（单步）、r（继续运行）等。如果大家不熟悉这些命令的使用方法的话，也可以输入help来查阅详细的帮助信息。

Step7. 为需要调试的Art虚拟机（大家要始终记住一点：虚拟机其实就是一个so库）功能设置对应的断点。例如我们希望调试ArtMethod::Invoke这个函数的处理逻辑，经查函数入口处在art_method.cc文件中的行数是370，那么可以使用如下命令设置断点：

```
b art_method.cc:370
```

如果以函数名来设置断点，那么要注意函数所属的Name Space亦要指定，范例如下：

```
(gdb) b Invoke
Function "Invoke" not defined.
Make breakpoint pending on future shared library load? (y or [n]) n
(gdb) b art::ArtMethod::Invoke
Note: breakpoint 17 also set at pc 0xb4a2f4ac.
Breakpoint 18 at 0xb4a2f4ac: file art/runtime/art_method.cc, line 369.
(gdb)
```

这样一来当程序成功运行到invoke函数时就会自动停下来了，如下所示：

```
(gdb) c
Continuing.

Breakpoint 14, art::ArtMethod::Invoke (this=this@entry=0x6ffd7220,
    self=0xb4e36a00, args=args@entry=0xbebb2ce4, args_size=4,
    result=result@entry=0xbebb2ccc, shorty=0x7057ad24 "L", shorty@entry=
    0xb4a285b9 <art::JniMethodEnd(unsigned int, art::Thread*)+12> "\370\304 \324
\370\234\060\020h\331h\335`\031a\304\370", <incomplete sequence \304>)
    at art/runtime/art_method.cc:370
370       if (UNLIKELY(__builtin_frame_address(0) < self->GetStackEnd())) {
(gdb) 
```

另外，GDB也可以对汇编代码进行调试，而且使用过程和C/C++并没有本质区别。一个简单的范例如下所示：

```
(gdb) b quick_entrypoints_arm.S:909

Breakpoint 4 at 0xb4a6d7d2: file art/runtime/arch/arm/quick_entrypoints_arm.S, line 909.
```

利用GDB调试可以在某些场合下很好地帮助我们理解Art这种复杂系统（当然，其他Android子系统也同样适用）的内部实现，建议大家在实践中充分应用好这一利器。

第22章 Android安全机制透析

22.1 Android Security综述

毋庸置疑，安全性一直是Android系统重点改进的方向之一（其他方向还包括系统性能等），它有专门的团队来负责安全性方面的改进工作——这是一项需要不断迭代演进的工作，同时也需要很多探索和“攻防之间的相生相克”过程。Android安全小组的活动包括但不限于如下几项（见图22-1）。

- 在一个Android新版本的早期阶段，负责安全性的团队会首先构建一个可配置和可扩展的安全模型。
- 接着在开发上述平台模型的过程中，他们还会根据Android Security Team、Google的Information Security Engineering Team，以及其他安全顾问的审视建议来实时调整安全策略。
- 除此以外，他们还会把设计方案开放给任何感兴趣的第三方人员，以便可以集合各方的建议来完善安全机制。
- 上述3个活动是在版本Release之前完成的，但并不代表Android系统发布后就一定没有安全性方面的问题了。所以Google还提供了各种其他反馈途径，来允许任何人对Android的安全性提出质疑和建议。
- Android Security Team每个月也都会提供安全方面的更新包给Google Nexus手机，以及各设备开发商。

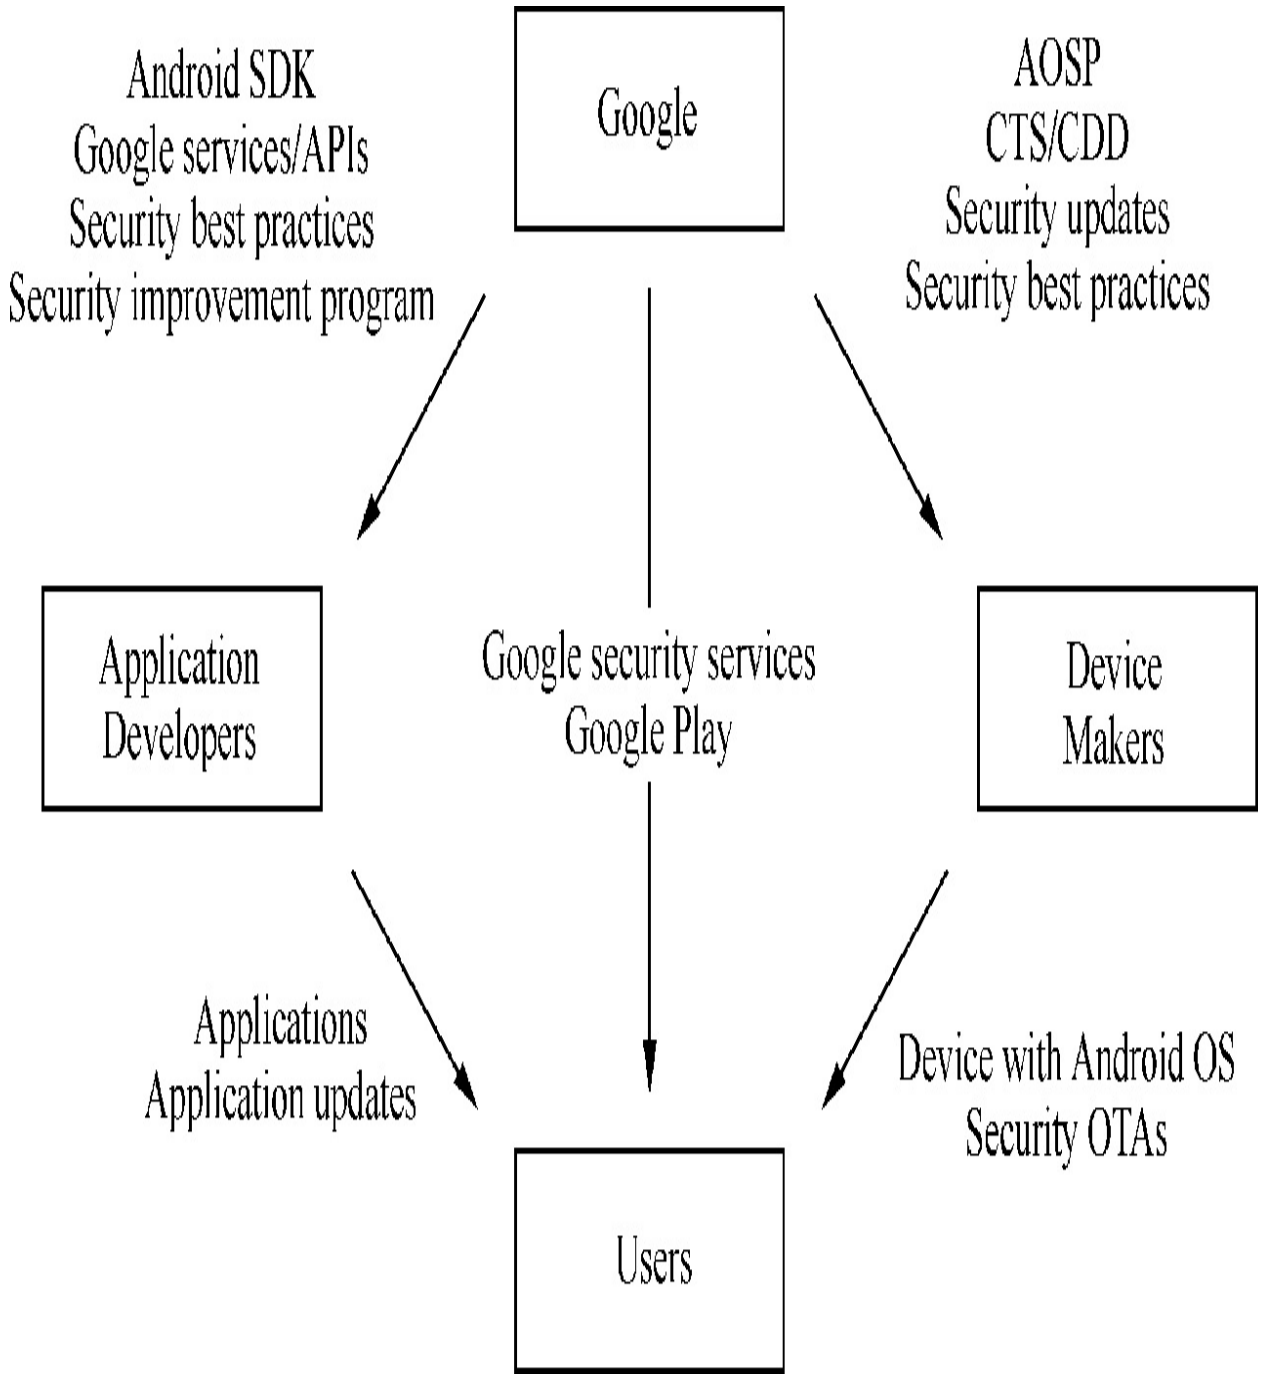

▲图22-1　安全服务

总体来说，Android系统主要从如下几个角度来保障安全性：

- 在Linux Kernel层应用各种安全机制，例如后续小节将会讲解到的DAC、SELinux等；

- 所有的应用程序都被强制运行在自己的sandbox中；
- 严格的进程间通信安全控制；
- 应用程序签名；
- Permission机制；

……

当然，我们也可以从内核层和应用程序层来考查Android系统的安全性：

- （1）Kernel层的安全保障

Linux Kernel经过这么多年的发展，其在安全性方面的长足进步是有口皆碑的，因而基于其上的Android系统自然可以利用已有的基础来做扩展实现。总体来说，Kernel为Android系统提供的关键安全特性包括但不限于：User-based Permission Model、Process isolation、Extensible mechanism for secure IPC等。

我们知道，每一个Android程序对于内核来说都是独立的进程，意味着它们之间可以充分利用UID和GID机制来做安全隔离。当然，Android系统为所有应用程序都提供了Unique User ID，而不是像很多其他操作系统那样，让多个进程以同一个User身份来运行——我们可以把这种做法称为具有Android特色的Sandbox。

内核的文件系统访问机制和UGO模型在Android系统中也同样适用。每个应用程序都有自己的私有数据，在没有特别允许的情况下，其他任何个体都无权访问，以避免破坏情况的发生。我们将在后续小节中做更详细分析。

除此之外，Android还引入了Security-Enhanced Linux，并根据其自身情况扩展而成SEAndroid。这使得设备即便是在被Root的情况下，也能尽量降低他人对重要资源的破坏力。我们在后续小节中对此同样有详细剖析。

- （2）应用程序层的安全保障

默认情况下，Android应用程序仅能访问一些非常有限的系统资源

（见图22-2）。对于那些很可能影响用户体验，及网络、数据、费用相关的操作，系统都会做严格的控制。例如：

- Camera functions；
- Location data (GPS)；
- Bluetooth functions；
- Telephony functions；
- SMS/MMS functions；
- Network/data connections。

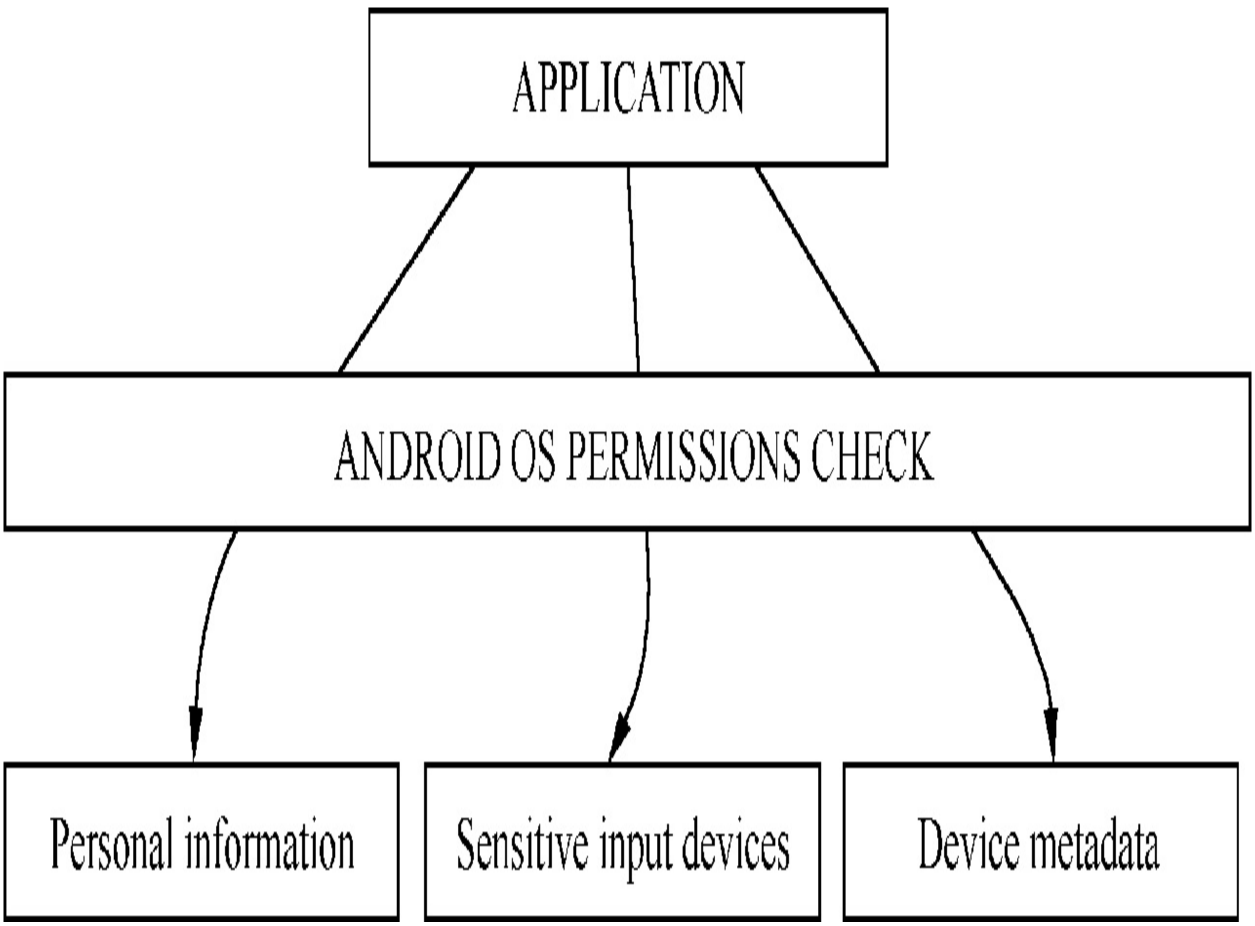

▲图22-2　应用层

如下则是一些可能会产生费用的程序操作范例：

- Telephony；
- SMS/MMS；

- Network/Data；
- In-App Billing；
- NFC Access。

相信大家已经想到了，完成上述安全保障的是Android开发人员很熟悉的Permission机制，我们也会在后续小节中做详细解读。

除此之外，对于大家非常关心的目前的一些主流技术，比如设备Root、程序加固、程序注入等，也将在本章节内容中得到阐述。

22.2　SELinux

22.2.1　DAC

在学习MAC之前，我们有必要先了解一下DAC，即Discretionary Access Control。Discretionary的字面意思是“任意的、自主的”，它很好地解释了DAC这种控制方式——客体的属主可以自主决定是否将全部或部分访问权限授予其他主体。主体通常是指进程/线程，而客户则是文件，文件夹、TCP/UDP端口、内存段、IO设备等各种资源。

举个例子来说，Linux系统中的UGO（User、Group和Others）权限模型就是DAC的一种表现形式。按照UGO的规定，权限主要分为读、写和执行3种，并且需要分别指定User用户、Group属组和Others对客体的访问权限。我们来看一个实际的例子：

```
[xs@lap~]$ ls -l
total 40
drwxr-xr-x  2 xs xs 4096 2010-05-24 17:04 Desktop
drwxr-xr-x  6 xs xs 4096 2010-05-24 13:10 Documents
drwxr-xr-x  9 xs xs 4096 2010-05-27 15:25 Download
-rw-rw-r--  1 xs xs    0 2010-05-28 10:21 example.txt
```

上面方框内的字符串就是UGO的一个典型范例。其中第一个字母位表示当前被描述对象是文件还是文件夹，后面9个字母则分别表示User、Group和Others（它们各占3个字母位）对这个文件的权限，比如rwx表示对象同时拥有读写和执行权限；rw-则表示有读写权限但缺乏执行权限。

值得一提的是，事实上Linux系统中还有一些比较特殊的权限位，例如SUID和SGID。从字面意思上理解，SUID（Set User ID）及SGID（Set Group ID）分别表示此可执行文件具有设置EUID和EGID的能力——程序中除了UID和GID外，还有EUID和EGID两个特殊ID，它们的默认值和前二者是分别对应的。而当程序执行了带有SUID和SGID的文件时，它的EUID和EGID会被重新设置为此文件属主的UID和GID。换句话说，它就具备了该文件属主（或Group）的资源访问权限，从而扩大了其原有的权限范围。SUID和SGID就好比一扇门，只要你进得去，就可以拥有更广阔的空间。或者你也可以把它理解为一次婚姻结合，让原本属于两个不同家族的人共享了双方原有的一些权利（如出入对方家族的住

宅，看一些私人物品等）。

在设备root过程中，通常会使用到的su文件就具备上述这个特性。它在ls命令中得到的权限位是：

-rwsr-sr-x root root0

另外，SUID和SGID在Linux系统中还有不少其他应用场景。例如Linux用户的密码存储在/etc/shadow等文件中，毫无疑问它们都属于需要被重点保护的对象，因而理论上只有root权限的进程才可以修改它们。但这同时也会出现一个矛盾，即普通用户如何更改自己的密码呢？打破僵局的是passwd。因为这个可执行文件的属主是root，而且具有SUID权限，这样一来执行它的进程就拥有了root权限，从而可以完成密码修改等关键操作。

有的读者可能会有这样的疑问——除了Read/Write之外，文件的创建和删除权限又是如何决定的呢？事实上Linux中的所有对象都可以被看做是“文件”，文件夹本身也不例外。换句话说，文件的创建和删除权限的决定权被牢牢掌握在包含它们的文件夹中。

22.2.2　MAC

MAC（Mandatory Access Control）是相对于DAC而言的。在强制控制方式中，主体访问客体的权力取决于操作系统的具体控制规则，而不是由属主自行决定。简单来说，当一个主体尝试去访问客体时，内核会首先检验本次访问是否符合安全规则，以决定是否允许操作的执行。

另外，MAC不允许用户制定或者修改权限规则，不管这种行为是有意还是无意的。所有权限策略都由一个Security Policy Administrator控制。

22.2.3　基于MAC的SELinux

SELinux（Security-Enhanced Linux）是一个负责安全管理的Linux内核模块，它提供了完善的机制来支持访问控制（Access Control）方面的安全策略，比如MAC（Mandatory Access Controls）。

SELinux最开始是由美国国家安全局开发的，后者于2000年的12月22日在开源开发社区发布了第一个基于GPL协议版本的SELinux。一开始的时候，开发人员需要手工将SELinux应用到内核源码中，但很快它的出色表现就赢得了大家的青睐，于是Linux Kernel从2.6版本开始就将它合并到主线中了。后来SELinux又被逐步应用到多个Linux发行版本中，从而为提升Linux系统的安全可靠性发挥了重要作用。

大家可以先从NSA的SELinux开发小组的如下声明中来感受一下：

“NSA Security-enhanced Linux is a set of patches to the Linux kernel and some utilities to incorporate a strong, flexible mandatory access control (MAC) architecture into the major subsystems of the kernel. It provides an enhanced mechanism to enforce the separation of information based on confidentiality and integrity requirements, which allows threats of tampering and bypassing of application security mechanisms to be addressed and enables the confinement of damage that can be caused by malicious or flawed applications. It includes a set of sample security policy configuration files designed to meet common, general-purpose security goals.”

由此可见：

- SELinux的架构核心是MAC；
- SELinux是针对内核的一系列“patch”，它们会“渗透”到内核的各个子系统中形成强大的保护网；
- SELinux希望基于confidentiality和integrity来建立起对信息的隔离访问控制；
- SeLinux是一个可配置的、灵活的安全机制。

SELinux作为Linux Kernel下的一种安全机制,很早之前就已经被集成到内核的主版本中了，但对于Android系统来说，这种保护直到5.0才得到全面和正式的应用。SELinux在安全方面至少可以给Android系统带来三大好处：

- SELinux可以全面保护Android中的各种系统daemon，让它们避免来

自恶意程序的危害；

- SELinux可以完全控制Android应用程序与内核层之间的交互，也能控制应用程序对系统资源的访问；
- SELinux提供了非常灵活的安全策略配置机制，使得Android系统无缝集成这一成熟机制成为可能。

接下来我们首先从框架层面来认识一下SELinux的全貌，如图22-3所示。

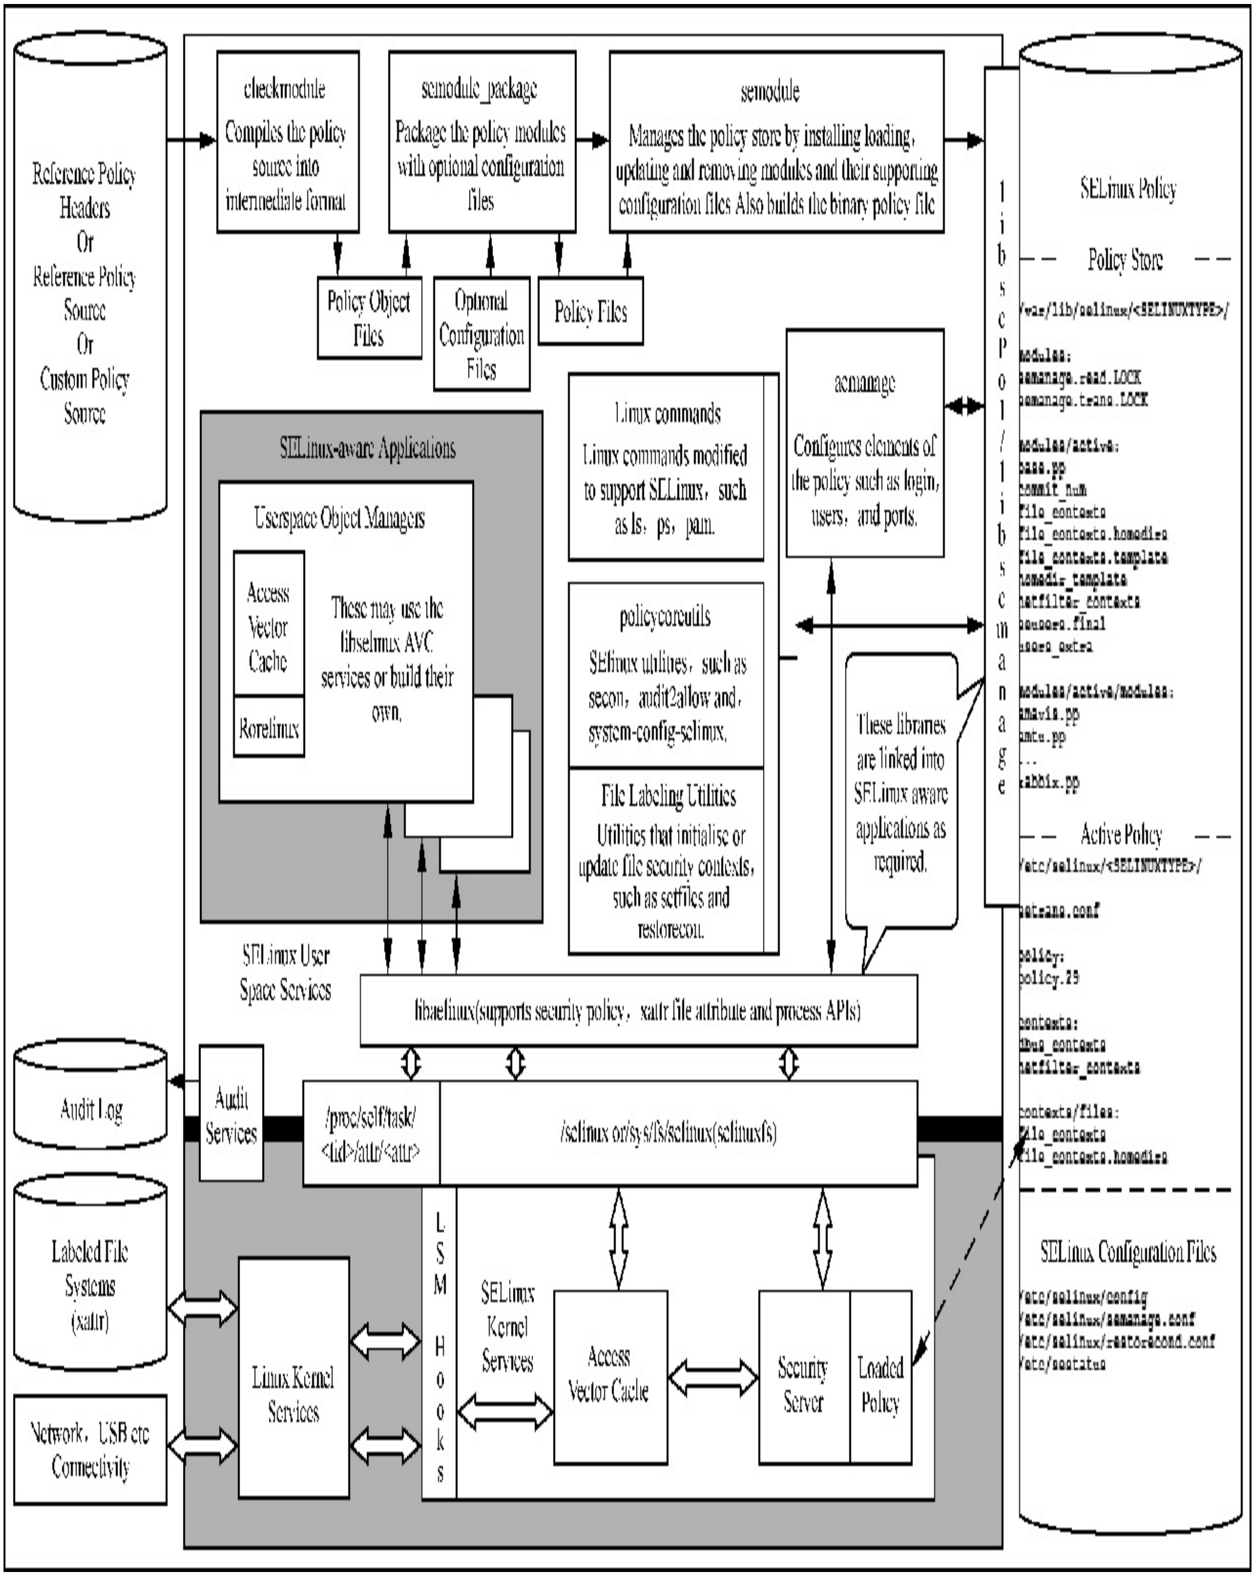

▲图22-3　SELinux架构图

引用自http://taiga.selinuxproject.org/~rhaines/NB4-diagrams/2-high-level-arch.png

首先大家要清楚一点，即SELinux架构的底层基础是Linux Security Modules（LSM）。LSM是Linux 2.6内核标准的一部分，并遵循GNU GPL开源协议。简单来讲，它的宗旨就是帮助Linux内核可以通过灵活的方式支持一系列第三方安全模块。比如下面这些都是基于LSM框架并已经获得kernel官方批准的优秀项目：

- AppArmor
- AppArmor是一个基于路径名的MAC服务，而且不需要对文件系统进行标签化。其官方网址是:
- http://wiki.apparmor.net
- SMACK
- 其全称为Simplified Mandatory Access Control Kernel，官方网址是:
- http://www.schaufler-ca.com
- Tomoyo
- 基于名称的一种MAC实现，其官方网址是:
- http://tomoyo.osdn.jp/
- SELinux
- 这是本小节的主角（见图22-4）。

SELinux在Linux内核工程中的源码位置是kernel\security\selinux，其下的文件结构如图22-5所示。可以看到，SELinux涉及的源文件并不多，有兴趣的读者可以自行挑选阅读。

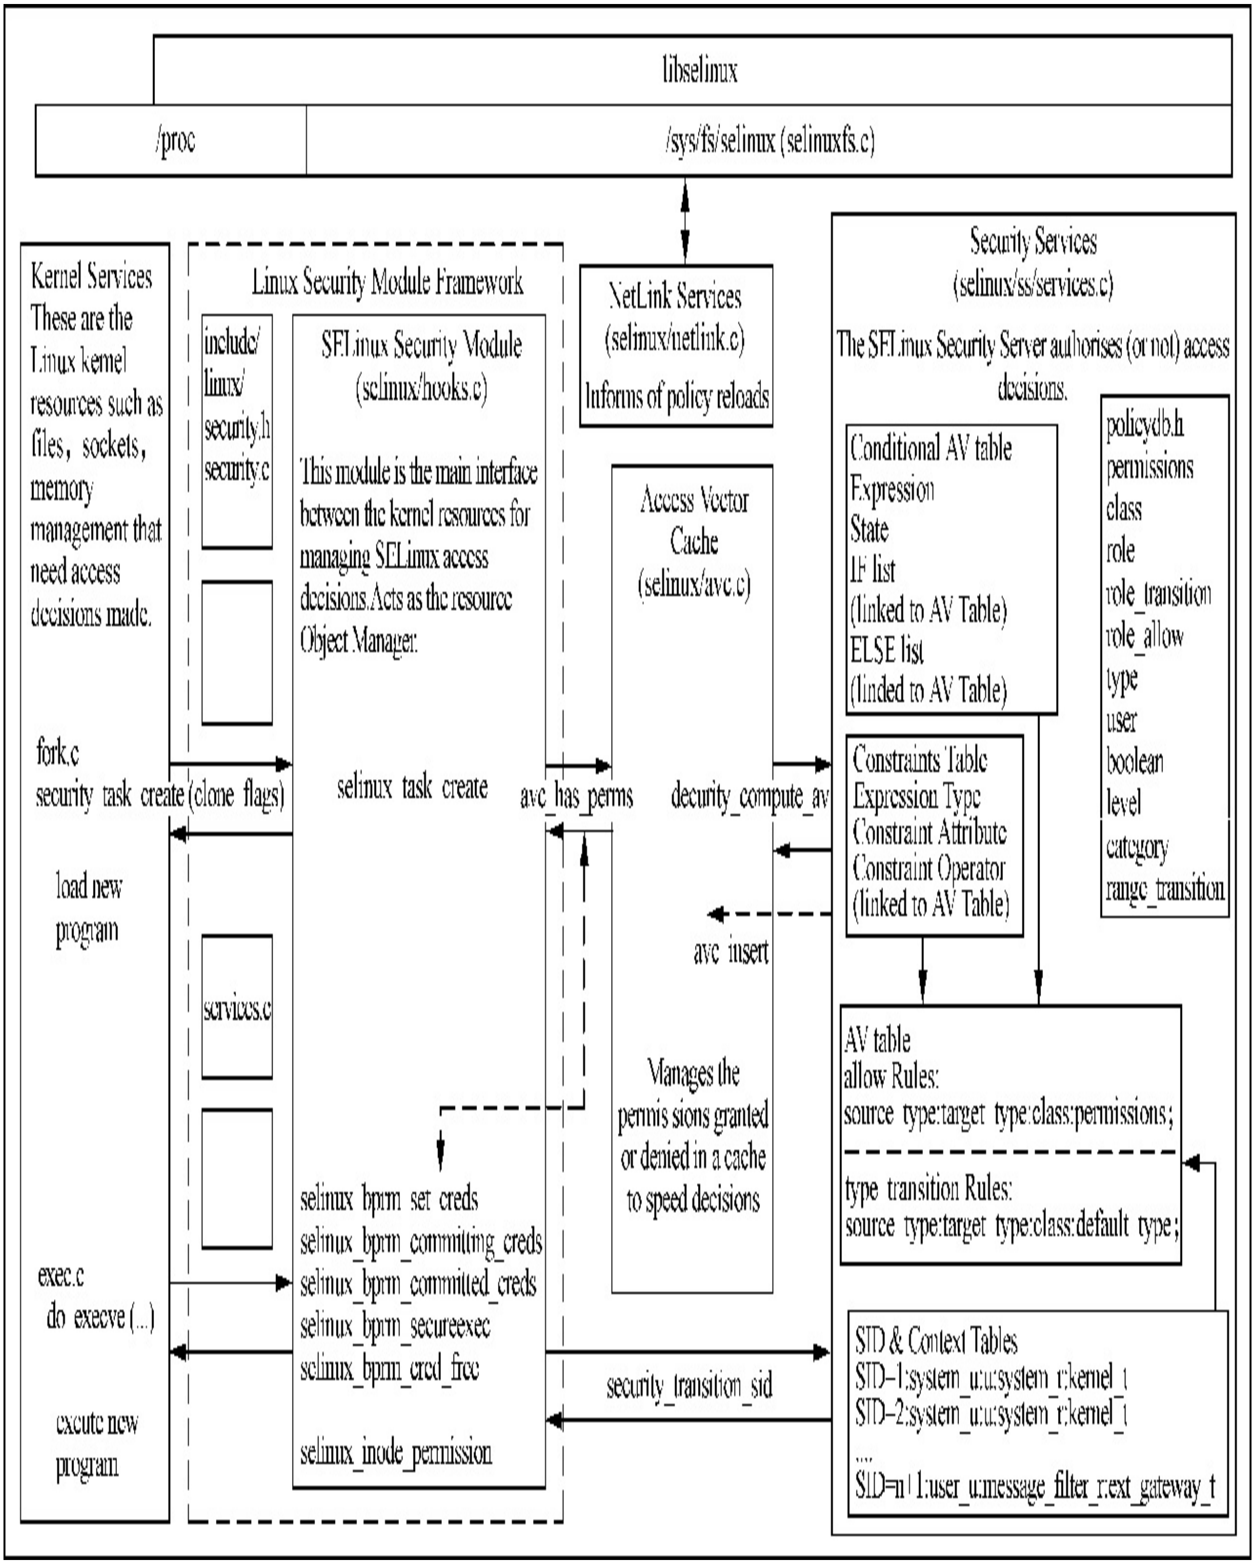

▲图22-4　SELinux主要模块关系图
引用自http://taiga.selinuxproject.org/~rhaines/NB4-diagrams/12-lsm-selinux-arch.png

include	2015/1/11 15:07	文件夹	
ss	2015/1/11 15:07	文件夹	
.gitignore	2014/11/23 3:33	GITIGNORE 文件	1 KB
avc.c	2014/11/23 3:33	C 文件	23 KB
exports.c	2014/11/23 3:33	C 文件	1 KB
hooks.c	2014/11/23 3:33	C 文件	147 KB
Kconfig	2014/11/23 3:33	文件	6 KB
Makefile	2014/11/23 3:33	文件	1 KB
netif.c	2014/11/23 3:33	C 文件	8 KB
netlabel.c	2014/11/23 3:33	C 文件	13 KB
netlink.c	2014/11/23 3:33	C 文件	3 KB
netnode.c	2014/11/23 3:33	C 文件	9 KB
netport.c	2014/11/23 3:33	C 文件	7 KB
nlmsgtab.c	2014/11/23 3:33	C 文件	7 KB
selinuxfs.c	2014/11/23 3:33	C 文件	44 KB
xfrm.c	2014/11/23 3:33	C 文件	11 KB

▲图22-5　SELinux源码目录

22.3　Android系统安全保护的三重利剑

Android系统的安全性一直以来都是大众诟病的重点之一。相对于Apple系统的闭源策略，Android的开源和开放性无疑会引发更多安全方面的潜在风险。

但是我们也要看到，Android系统一直在努力提升自身的安全性，例如它基于SELinux扩展出了SEAndroid，即Security Enhancements for Android™（SE for Android）。

起初，SEAndroid只是将SELinux引进到了Android系统中，以控制恶意应用程序所带来的危害。随着时间的推移，这个项目已经不仅仅是使用SELinux这么简单了，Android针对自身的特点做了不少关键的扩展和改进——Android从4.3版本开始支持SELinux;Android 4.4版本则将SELinux变成了强制模式；而到了Lollipop时期，Android中所有的服务和应用程序都能得到SELinux的全面保护了。

不过需要特别指出的是，Android并没有因为“新欢”（SEAndroid）而摒弃“旧爱”（DAC访问机制）。这两种安全机制之间是一种“与”的关系，它们共同构成Android安全控制的两堵坚实的城墙——任何核心资源的访问操作都需要同时符合SEAndroid和DAC的安全控制。如图22-6所示。

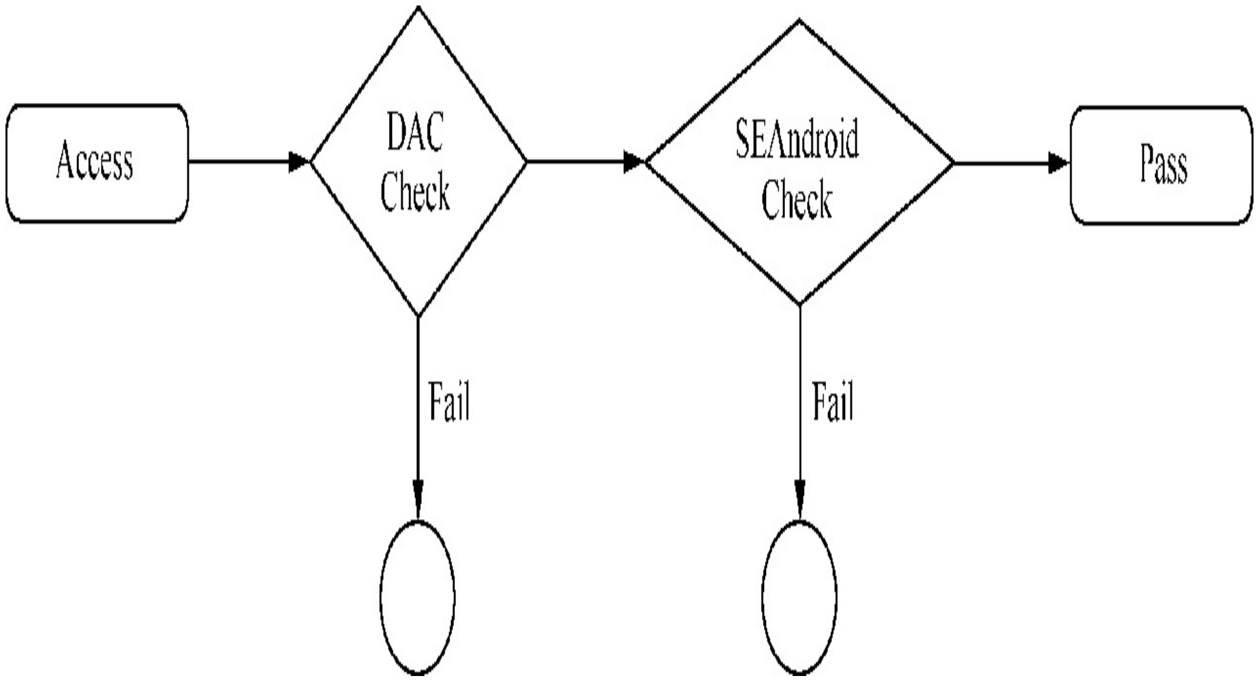

▲图22-6 Android系统中的双重保护机制

另外，上层应用程序还同时受到Permission机制的约束。所以接下来我们将通过3个小节来分别针对它们做细化分析。

22.3.1 第一剑：Permission机制

不论是Android应用程序开发者还是系统程序员，相信都不会对Permission机制感到陌生。简而言之，Permission是Android应用程序、Android系统和用户的基础安全保障。任何类似于读写用户私人数据（譬如E-mail和联系人）、应用程序文件或者网络访问等行为都需要首先经过系统的权限授予。

那么Permission具体是如何发挥作用的呢？

我们知道，Android应用程序运行于进程沙盒（Sandbox）中。Sandbox是分离运行程序的一种安全手段。它常被用于为不被信任的程序（比如未知的第三方软件，无法核实的网址等）提供特殊的运行环境。目的是显而易见的，就是为了防止这些程序产生各种形式的破坏。这也就决定了运行于其中的程序将受到高度控制，特别是对于资源的访问更是如此。

正因为如此，Android中的应用程序在默认情况下都没有访问资源或数据的权利，当它们希望执行类似操作时就要显性地做出申请，即声明各种Permissions。声明过程并不复杂，主要是通过AndroidManifest.xml中的<uses-permission>标签来完成。下面是Android官方提供的一个例子：

```
<manifest xmlns:android="http://schemas.android.com/apk/res/andro
    package="com.android.app.myapp" >
    <uses-permission android:name="android.permission.RECEIVE_SMS
    ...
</manifest>
```

可以看到，这个应用程序范例主动申请了一个接收短信的权限。

表22-1是Android系统中的一些常见权限的节选，大家可以熟悉一下。

表22-1　常见Permission释义

Permissions	Description
BATTERY_STATS	允许应用程序收集电池相关的数据
BROADCAST_SMS	允许应用程序发送“设备接收到新SMS的广播”
CALL_PHONE	允许应用程序发起一个主叫通话
CAMERA	允许应用程序使用摄像头硬件设备
FLASHLIGHT	允许应用程序使用闪光灯

INSTALL_PACKAGES	允许应用程序安装Packages
INTERNET	允许应用程序打开网络sockets
LOCATION_HARDWARE	允许应用程序使用相关硬件设备中的定位功能
READ_CALENDAR	允许应用程序读取日历数据
READ_CALL_LOG	允许应用程序读取用户的通话记录
READ_CONTACTS	允许应用程序读取通信录

系统会在以下两种情况中使用到应用程序在AndroidManifest.xml中声明的Permission（注意：Android M以上版本中针对某些核心权限的处理过程发生了变化，参见Runtime Permission）：

- 应用程序安装时

在应用程序的安装过程中，会在设备屏幕弹出一个提示框指明此APPLICATION声明的所有权限。如果用户拒绝了它的权限申请，那么安装过程将直接失败；否则系统的Package Installer才会继续进行。一个典型范例如图22-7所示。

- 应用程序运行过程中
- 当应用程序在运行过程中执行已经申请过权限的操作时，Android系统并不会再次询问用户。这样做的目的是为了不反复骚扰用户，造成不好的用户体验。

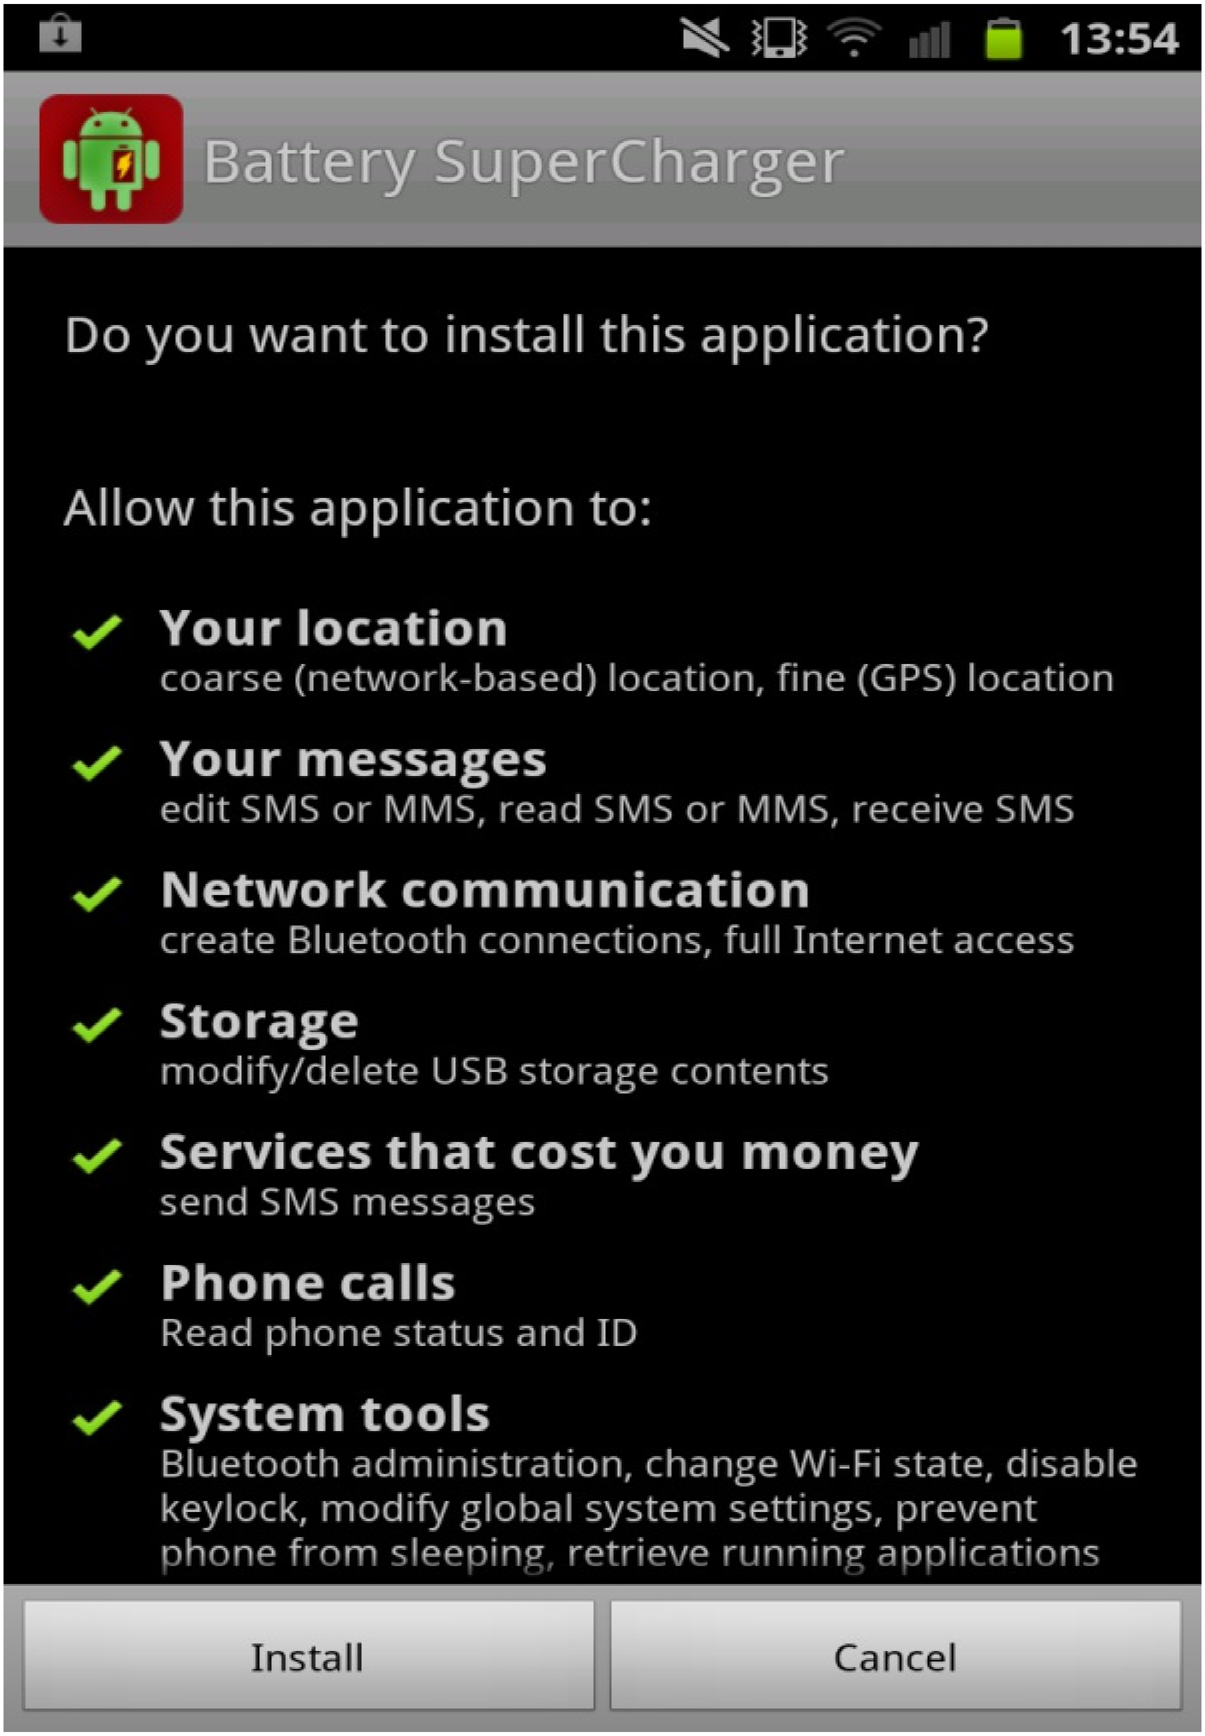
13:54
Battery SuperCharger
Do you want to install this application?
Allow this application to:
Your location
coarse (network-based) location, fine (GPS) location
Your messages
edit SMS or MMS, read SMS or MMS, receive SMS
Network communication
create Bluetooth connections, full Internet access
Storage
modify/delete USB storage contents
Services that cost you money
send SMS messages
Phone calls
Read phone status and ID
System tools
Bluetooth administration, change Wi-Fi state, disable keylock, modify global system settings, prevent phone from sleeping, retrieve running applications
Install
Cancel

▲图22-7　应用程序安装过程中的权限申请

随着Android版本的演进，不断会有新增的Permissions被加入到系统中——而且新的平台版本针对某些核心权限的控制也呈现逐步加强的趋势。比如Android旧平台（API等级3及以下）中是可以不用申请WRITE_EXTERNAL_STORAGE的，但随后的版本中就明确规定了应用程序必须显式声明这一权限了。大家应该能想到，这种变化首先要解决的一个问题是，新平台如何保证对老应用程序的兼容性。

Android针对这个问题的解决办法是：系统会自动判断是否可以为旧平台版本中的应用程序添加新平台版本中的对应权限。具体来说，当老应用程序的targetSdkVersion属性低于该权限出现时的API等级，那么系统将自动为其授权，以保证它在新平台上可以继续稳定地运行。

那么对于那些没有按照要求申请权限的应用程序，系统会有哪些强制手段呢？接下来我们以网络访问为例，具体剖析下Android系统是如何利用Permission机制来控制应用程序权限的。

Android系统会为设备中所有受保护的资源“贴上”Permission标签，并提供便捷的通道供开发人员主动申报相关的权限。下面是系统规定的，访问网络资源需要主动申请的Permission：

```
<uses-permission android:name="android.permission.INTERNET"></use
```

如果应用程序希望访问网络功能，那么它需要在AndroidManifest.xml中添加上述的语句，否则系统就会抛出异常。如图22-8所示。

```
05-25 21:45:54.430  21958-22006/? E/AndroidRuntime:  FATAL EXCEPTION: Thread-1231
    Process: com.example.myapp, PID: 21958
    java.lang.SecurityException: Permission denied (missing INTERNET permission?)
            at java.net.InetAddress.lookupHostByName(InetAddress.java:464)
            at java.net.InetAddress.getAllByNameImpl(InetAddress.java:252)
            at java.net.InetAddress.getAllByName(InetAddress.java:215)
            at com.android.okhttp.internal.Network$1.resolveInetAddresses(Network.java:29)
            at com.android.okhttp.internal.http.RouteSelector.resetNextInetSocketAddress(RouteSelector.java:188)
            at com.android.okhttp.internal.http.RouteSelector.nextProxy(RouteSelector.java:157)
            at com.android.okhttp.internal.http.RouteSelector.next(RouteSelector.java:100)
```

▲图22-8　网络权限缺失所导致的异常情况

当应用程序在设备中安装时，PackageManagerService会扫描APK，提取出其中声明的< uses-permission>加以保存，并根据具体情况将其加入系统的相应群组中。接下来的安全检查分为两种情况：既有可能是Android系统提供的API自身就会针对程序身份和操作做安全检查；也有可能是API在进一步调用内核层的功能时，由于应用程序不是相应群组的成员而触发安全问题——不难发现，上述这个范例就是因为执行到lookupHostByName时，Android系统catch到了一个SecurityException而导致的失败。

类似的例子还有很多，例如不少应用程序都需要访问SDCARD目录下的文件，此时也会有安全检查的过程。对于开发人员来说，Java的标准API就提供了文件访问的能力，因而java.io.File是他们比较常用的一个类。Android N版本中的核心库(libcore)会分为两部分，其一是移植自OpenJDK的，被保存在/libcore/ojluni路径下;其二是Android的差异实现，主要集中在/libcore/libart和其他相关目录中。以下面的语句为例：

```
String FILENAME = "hello_file";
String string = "hello world!";

FileOutputStream fos = openFileOutput(FILENAME, Context.MODE_PRIV
fos.write(string.getBytes());
fos.close();
```

这里的FileOutputStream ::write会调用IoBridge.write，后者则进一步通过Libcore.os.write来写数据到文件中。Libcore.os是一个BlockGuardOs类型的静态变量，定义如下：

```
public final class Libcore {…
    public static Os os = new BlockGuardOs(new Posix());
```

BlockGuardOs构造函数所带参数代表的是实现了Os接口的一个类对象，即Posix。在我们这个场景中，Posix提供的write功能又将调用native函数writeBytes进入本地层。关系如图22-9所示。

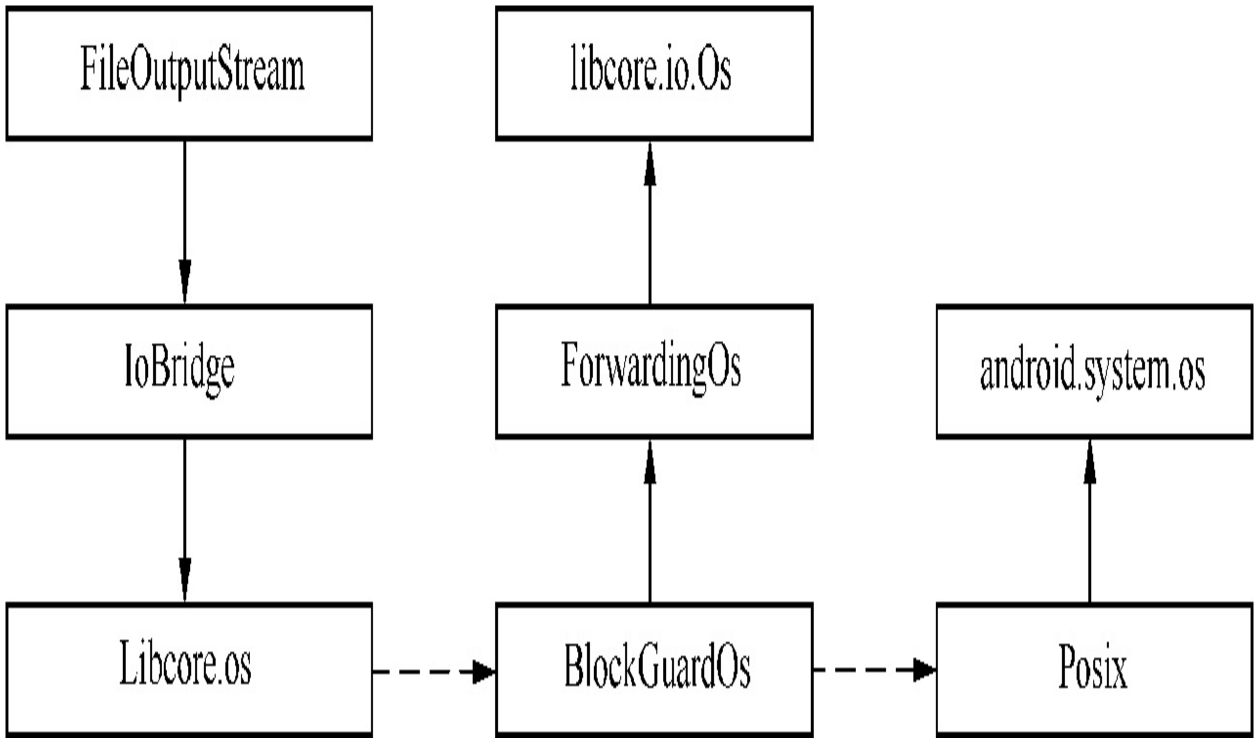

▲图22-9　FileOutputStream的内部实现关系图

首先，Android系统需要对程序的某些文件写入行为（其他行为也是类似的）进行拦截，以便执行诸如StrictMode之类的检查。比如在我们这个场景中：

```
/*libcore/luni/src/main/java/libcore/io/BlockGuardOs.java*/
public int write(FileDescriptor fd, byte[] bytes, int byteOffset,
throws ErrnoException, InterruptedIOException {
         BlockGuard.getThreadPolicy().onWriteToDisk();
         return os.write(fd, bytes, byteOffset, byteCount);
    }
```

StrictMode是辅助开发人员进行应用程序调优的一种模式，它提供的多种策略可以让我们甄别应用程序在运行过程中是否在磁盘读写、网络访问、运行性能等多个方面存在不足，从而有针对性地进行改进。

另外，从操作系统的层面来说Java API也属于上层实现，因而它的功能是要由操作系统的接口来提供支撑的——这有点类似于libc库和系统API之间的关系。譬如上述os.write就是由Posix提供的，实现如下：

```
/* libcore/luni/src/main/java/libcore/io/Posix.java*/
public int write(FileDescriptor fd, byte[] bytes, int byteOffset,
```

```
throws ErrnoException, InterruptedIOException {
        //This indirection isn't strictly necessary, but ensures
        //is type safe.
        return writeBytes(fd, bytes, byteOffset, byteCount);
    }
    private native int writeBytes(FileDescriptor fd, Object buffe
```

可以看到writeBytes是一个native函数，它在内部可以通过C/C++库来进一步完成应用程序的write请求。不过到目前为止，我们似乎还没有看到系统是如何对应用程序进行文件写入权限的检查的。大家可以先想想看权限检查应该放在哪一个阶段比较合适呢？

对于Android 6.0之前的系统，答案就在于当应用程序在AndroidManifest.xml中声明了WRITE_EXTERNAL_STORAGE时,那么它所归属的Groups中就会有AID_SDCARD_RW(1015)，这样一来该应用程序就具有写入SDCARD的能力了。反之如果没有声明WRITE_EXTERNAL_STORAGE，那么应用程序就无法向SDCARD正确地写入数据了。图22-10中的左边是应用程序申请了WRITE_EXTERNAL_STORAGE权限的情况，右边则是没有申请权限的情况。我们使用的命令是：cat /proc/<pid>/status）如图22-10所示。

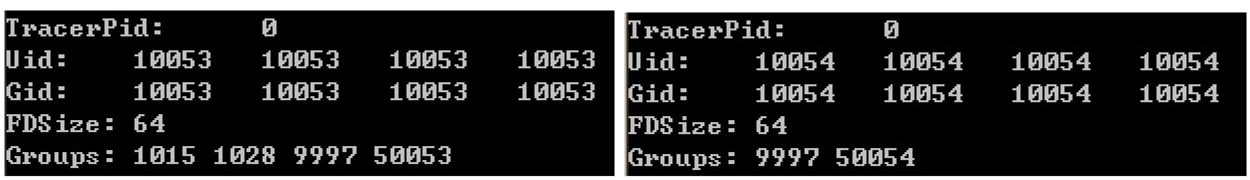

▲图22-10　应用程序申请权限前后的情况对比

Android 6.0和后续版本中因为加入了Runtime Permission的功能，权限的控制方式也有所变化。应用程序不光要在AndroidManifest.xml中主动声明需要使用到的所有普通和敏感权限，而且需要在运行过程中显式地请求敏感权限（除非用户已经允许过这一权限，并勾选了“不再询问”的选项）。用户同意或者拒绝应用程序的动态权限申请则会直接影响到它所能看到的“Mount View”，从而决定了应用程序是否可以成功向SDCard中写入数据。更多细节可以参见本书其他章节的分析。

22.3.2　加强剑：DAC（UGO）保护

即传统的Linux UGO文件访问机制。从图22-11中可以看到，即便是最新的Android操作系统，仍然没有摈弃这个传统的安全保障手段——毕竟经历了这么多年的考验，UGO的表现虽然中规中矩，但依然能起到一定的保护作用。

```
drwxr-xr-x root     root              1970-01-01 01:00 mnvm2:0
drwxr-xr-x root     root              2011-01-01 20:45 modem_log
dr-xr-xr-x root     root              1970-01-01 01:00 proc
-rw-r--r-- root     root         2161 1970-01-01 01:00 property_contexts
drwx------ root     root              2015-02-12 21:05 root
drwxr-x--- root     root              1970-01-01 01:00 sbin
lrwxrwxrwx root     root              2015-04-22 05:10 sdcard -> /storage/emulat
ed/legacy
-rw-r--r-- root     root          719 1970-01-01 01:00 seapp_contexts
-rw-r--r-- root     root        74665 1970-01-01 01:00 sepolicy
drwxrwxr-x root     root              2011-01-01 20:45 splash2
drwxr-x--x root     sdcard_r          2015-04-22 05:10 storage
dr-xr-xr-x root     root              2015-04-22 05:10 sys
drwxr-xr-x root     root              2015-03-16 07:03 system
-rw-r--r-- root     root            0 1970-01-01 01:00 ueventd.41033.rc
-rw-r--r-- root     root            0 1970-01-01 01:00 ueventd.4622.rc
-rw-r--r-- root     root            0 1970-01-01 01:00 ueventd.4845.rc
-rw-r--r-- root     root            0 1970-01-01 01:00 ueventd.5821.rc
-rw-r--r-- root     root            0 1970-01-01 01:00 ueventd.71424.rc
-rw-r--r-- root     root         1896 1970-01-01 01:00 ueventd.hi3630.rc
-rw-r--r-- root     root         4631 1970-01-01 01:00 ueventd.rc
-rw-r--r-- root     root           41 1970-01-01 01:00 update_commit_boot
lrwxrwxrwx root     root              2015-04-22 05:10 vendor -> /system/vendor
```

▲图22-11　Android系统中的UGO机制

UGO机制在Android系统和Linux中的表现基本上是一致的，只不过我们还要额外思考的一个问题是：Linux是一个多用户系统（注：Android也支持多用户的概念，但和传统的多用户系统有不小的差异），但是Android则不存在“用户登录”的过程，那么它是如何区分不同“User”的呢？

在回答这个问题之前，我们可以首先对安全机制做一个抽象，如图22-12所示。

▲图22-12　安全机制的抽象

无论具体的安全机制怎么变化，它们本质上要回答的问题是不变的，即主体访问客体的规则是什么。

依照这一基础原理，我们当然需要思考一下Android系统下的主体是谁？没错，无非还是进程/线程。那么这样就好办了，Linux系统既然是通过当前登录的用户身份来给予主体相应的UID和GID等属性，那么Android系统也完全可以制定另外一个规则，来赋予每个主体自己的UID和GID。具体而言，Android系统中运行的进程的UID和GID是由PackageManagerService分配的，而且是在APK安装之初就确定下来了（更为有趣的是，每一个APK都会被赋予一个不同的UID）——和Linux的做法相比其实就是“换汤不换药”。我们可以参考Process.java中对UID的分类，如表22-2所示。

表22-2　UID分类

UID	Value	Description
ROOT_UID	0	Root UID
SYSTEM_UID	1000	UID under which system code runs
PHONE_UID	1001	UID under which telephony code runs
SHELL_UID	2000	UID for shell
LOG_UID	1007	UID for log group
WIFI_UID	1010	UID for WIFI supplicant process
MEDIA_UID	1013	UID for mediaserver process

DRM_UID	1019	UID for DRM process
VPN_UID	1016	UID for VPN services
NFC_UID	1027	UID for NFC service process
BLUETOOTH_UID	1002	UID for Bluetooth service process
FIRST_APPLICATION_UID	10000	为应用程序预留的UID区域的起点值
LAST_APPLICATION_UID	19999	为应用程序预留的UID区域的终止值

这样一来Android中的UGO机制和Linux中的经典实现就没有太大区别了。对于Linux UGO的更多信息，建议大家可以自行查阅相关资料了解。

22.3.3 终极剑：SEAndroid

相信不少开发者都会有过类似的经历——虽然“×××一键ROOT神器”显示手机已经root成功了，但访问一些文件时仍然会发生权限不足的错误。这实际上就是得益于SEAndroid对设备的全面保护了。

与SEAndroid相关的一系列重要的Papers和出版物如下所示，大家可以和本小节内容结合起来阅读理解：

- The Case for SE Android, Linux Security Summit 2011, Sep 2011.
- The Case for Security Enhanced (SE) Android, Android Builders Summit

2012, Feb 2012.

- Security Enhanced (SE) Android, LinuxCon North America 2012, Aug 2012.
- Middleware MAC for Android, Linux Security Summit 2012, Aug 2012.
- Security Enhanced (SE) Android: Bringing Flexible MAC to Android, 20th Annual Network and Distributed System Security Symposium (NDSS '13), Feb 2013.
- Laying a Secure Foundation for Mobile Devices, 20th Annual Network and Distributed System Security Symposium (NDSS '13), Feb 2013.
- Laying a Secure Foundation for Mobile Devices, International Council on Systems Engineering (INCOSE) Chesapeake Chapter Monthly Meeting, Aug 2013.
- Security Enhancements (SE) for Android, Android Builders Summit 2014, Apr 2014.
- Protecting the Android TCB with SELinux, Linux Security Summit 2014, Aug 2014.

在开启了SEAndroid的设备中，通过Adb命令getenforce可以得到如下信息：

```
shell@hwmt7:/ $ getenforce
getenforce
Enforcing
```

这个状态从Android 4.4以后就成了一种强制行为了，除非传递给内核的参数中带有androidboot.selinux=permissive ——此时不符合SEAndroid规则的非法访问只会被记录成log，系统并不会强制禁止它的执行，SEAndroid的发展时间表如图22-13所示。

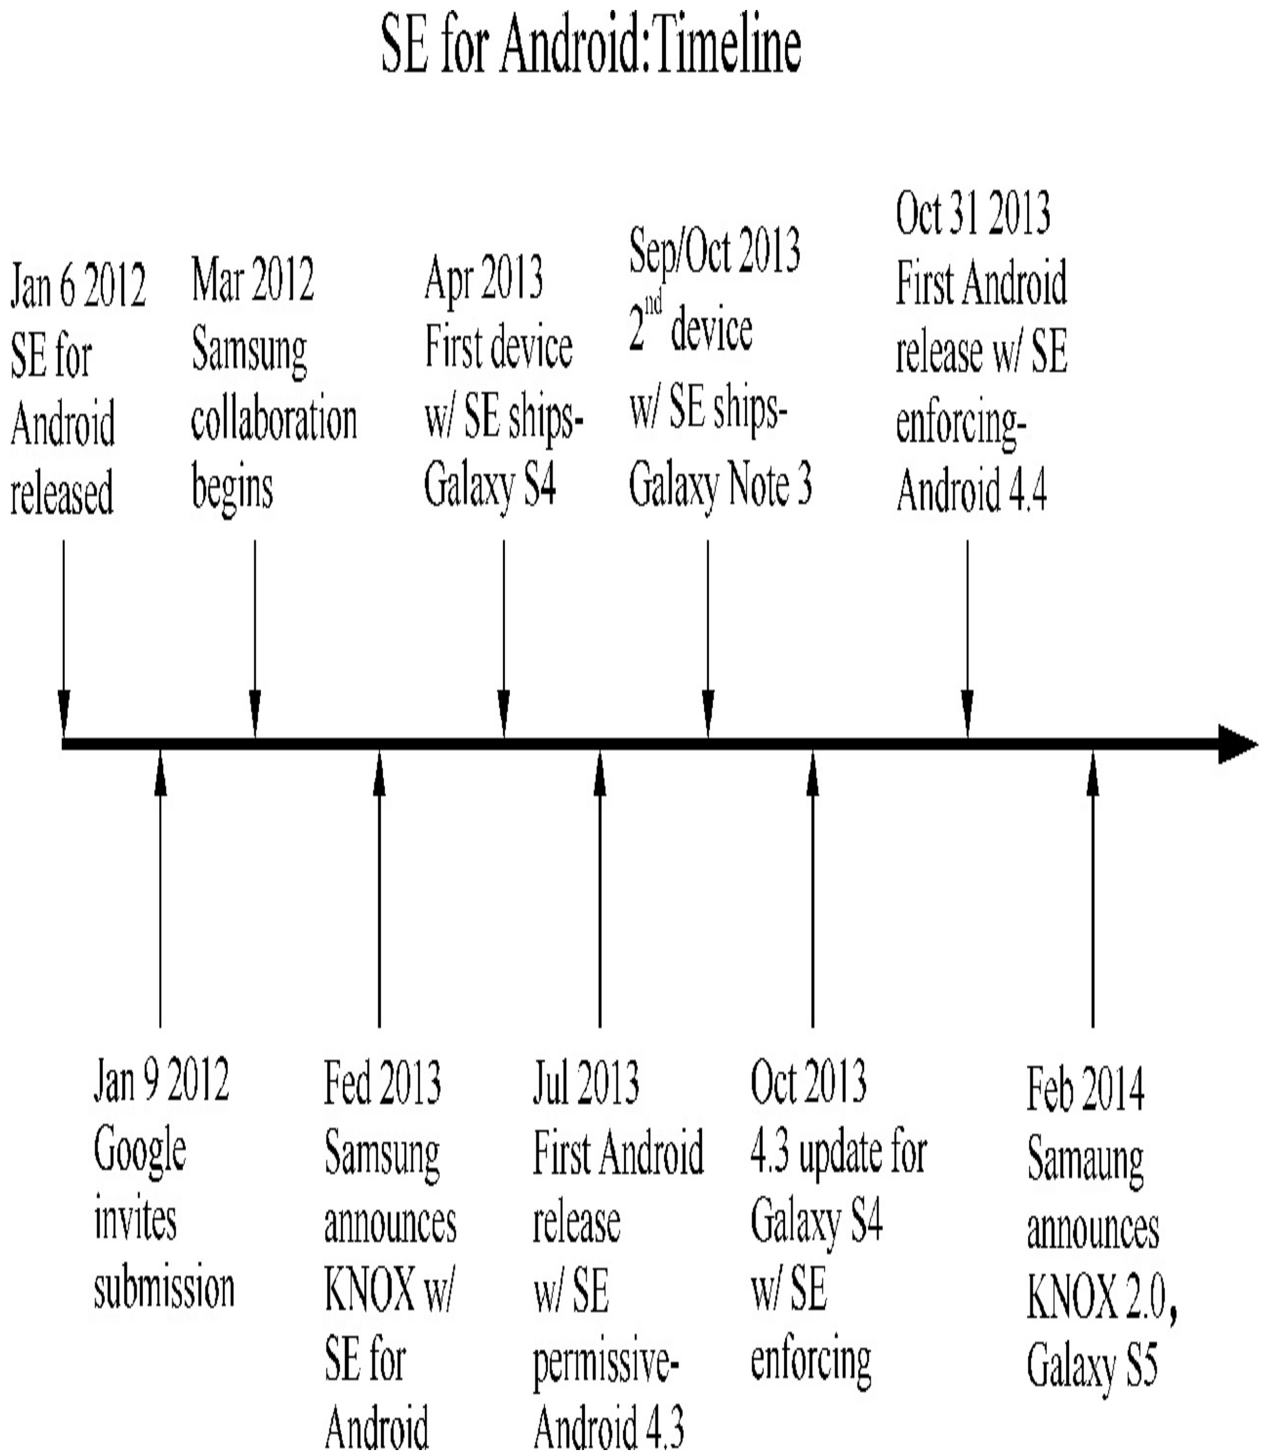

▲图22-13　SEAndroid的发展时间表

（引自Security Enhancements (SE) for Android, Android Builders Summit 2014）

我们在上一小节对安全机制进行了一个抽象，并提出它需要回答的问题是——主体访问客体的规则是什么。对于SEAndroid来说，这个问

题也同样适用。

在SEAndroid机制中，主体和客体的安全标签与UGO相比发生了非常大的变化。我们可以通过如下命令来显示客体的SEAndroid安全标签：

```
ls   –Z   [Object]
```

比如下面所示的例子：

```
C:\Users\xs0>adb shell
shell@hwmt7:/ $ ls -Z /system/bin/vold
ls -Z /system/bin/vold
-rwxr-xr-x root     shell            u:object_r:unlabeled:s0 vold
shell@hwmt7:/ $ ls -Z /init
ls -Z /init
-rwxr-x--- root     root             u:object_r:rootfs:s0 init
```

还可以通过如下命令来显示主体的SEAndroid安全标签：

```
ps   –Z   [Subject]
```

比如下面所示的例子：

```
shell@hwmt7:/ $ ps -Z com.huawei.ca
ps -Z com.huawei.ca
LABEL                          USER     PID   PPID  NAME
u:r:system_app:s0              system    3381  2421  com.huawei.ca
shell@hwmt7:/ $ ps -Z adbd
ps -Z adbd
LABEL                          USER     PID   PPID  NAME
u:r:adbd:s0                    shell     31297 1     /sbin/adbd
```

由于SEAndroid涉及的知识面比较多，我们将分为几个小节来对其进行深入分析。

22.4 SEAndroid剖析

22.4.1 SEAndroid的顶层模型

我们在前面讲解Linux UGO时针对安全机制所做的模型抽象对于SEAndroid也是适用的。只不过它的Label不再是UID/GID了，取而代之的是“user:role:type:security”这个SELinux的安全上下文；安全规则也不再是简单固定的UGO，而是需要由sepolicy来定义具体的访问权限了。另外，SEAndroid主要通过Label中的Type来定义安全策略，所以又被称为Type Enforment（这也是它的.te文件后缀的由来）。

根据SEAndroid顶层模型的描述（见图22-14），我们不难理解它在设计过程中需要重点回答如下几个问题。

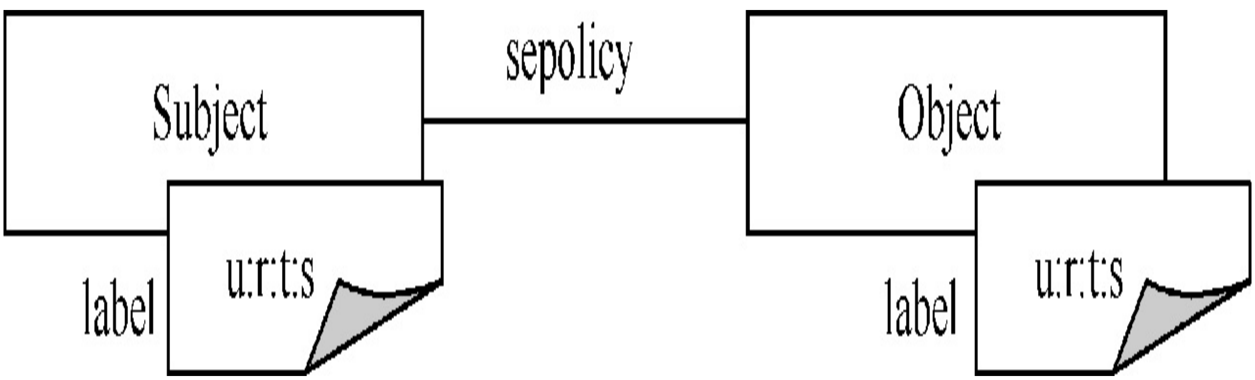

▲图22-14　SEAndroid的顶层模型

- Label的格式和安全规则的定义
- Label是由4个部分组成的，它们又分别有哪些具体的规定？除了Google原生的设计外，各设备厂商是否可以自定义自己的安全规则？
- 系统是在什么时候，如何确定某个Subject（主体）的具体Label的？
- 系统是在什么时候，如何确定某个Object（客体）的具体Label的？
- 系统是在什么时候，又是如何应用Subject和Object之间的安全规则的？

22.4.2 SEAndroid相关的核心源码

与SEAndroid相关的源码目录主要是。

- /system/sepolicy：安全策略源文件所在目录，大多数是以.te结尾的文件。
- /system/sepolicy/tools：包含了编译安全策略文件所需的一系列工具。
- /external/libselinux：用于生成支撑Android系统中实现Selinux的一个动态库。

其中external/libselinux中相关的源码文件结构如图22-15所示。

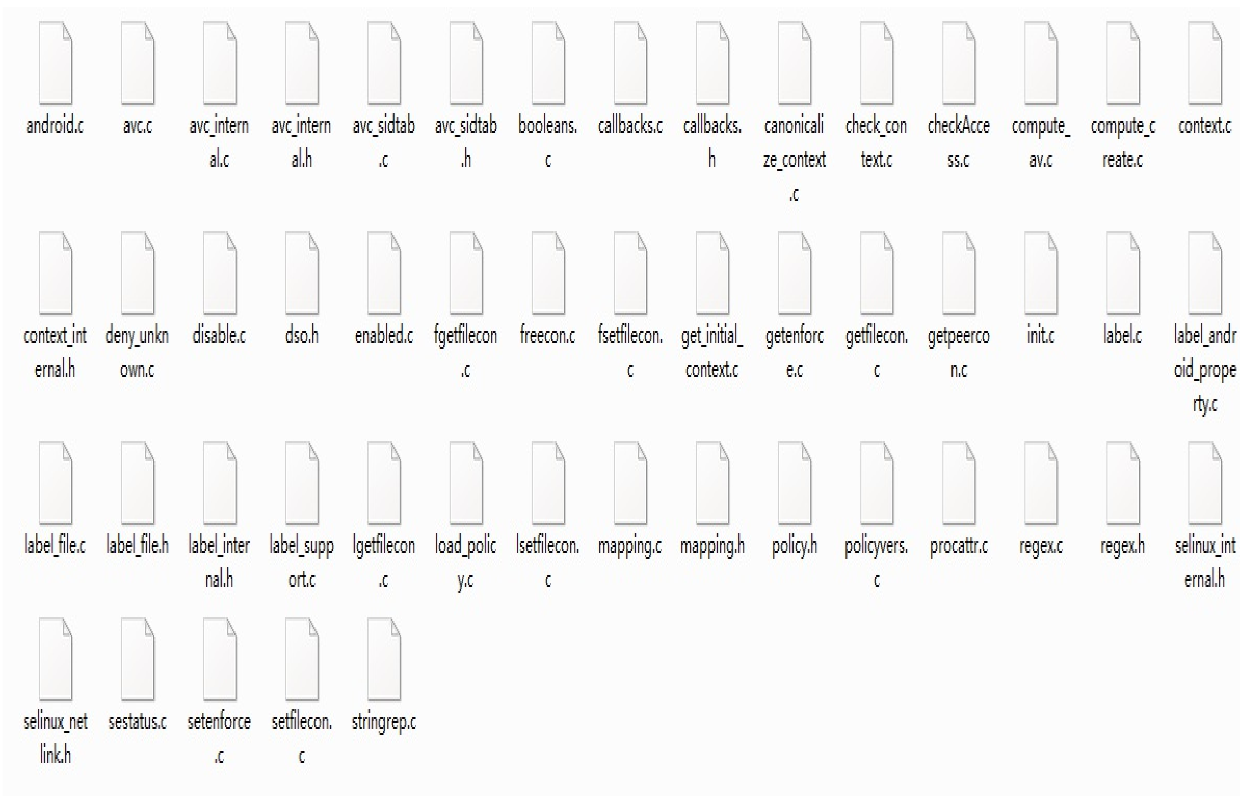

▲图22-15　文件结构

系统预定义的安全规则放置在/system/sepolicy中；各厂商自定义的te文件则多数位于/device/[manufacturer]/device-name/sepolicy目录下，如图22-16所示的范例。

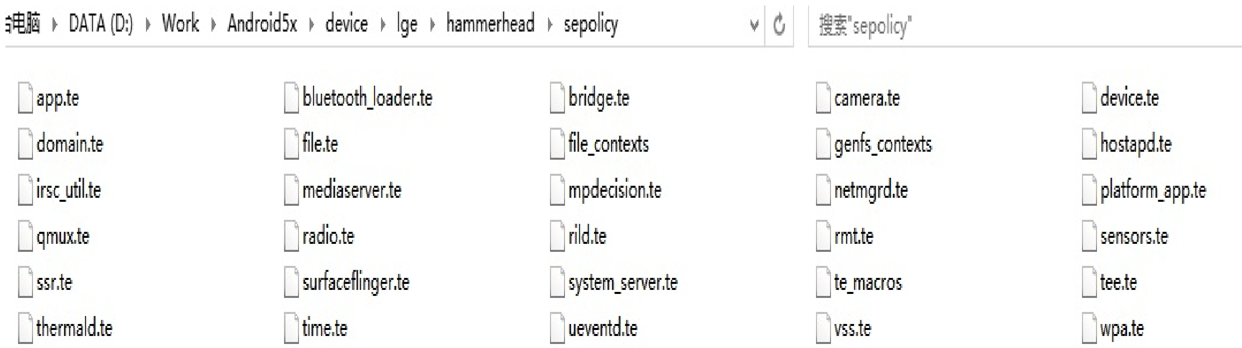

▲图22-16　范例

其中：

- file_contexts
- 既包括编译过程中文件的安全标签，也用于在运行时态对设备节点、socket端口、init.rc产生的/data目录进行安全标签的规划。当你创建新的安全策略时，在某些情况下需要更新这个文件来分配新的标签。而为了让新标签生效，我们必需重新编译文件系统image或者执行restorecon。
- genfs_contexts
- 这个文件用于为不支持扩展属性的文件系统（例如proc和vfat）添加标签。这个配置将作为核心策略的一部分被加载。
- property_contexts
- 这个文件用于制定Android系统各属性的标签，以确定哪些进程可以设置它们。它将在系统启动时的init进程中被加载，或者是当selinux.reload_policy被置于1时被重新加载。
- mac_permissions.xml
- Middleware MAC policy，即MMAC。这个文件会根据应用程序的签名以及包名（可选）来为它们分配seinfo标识。然后在seapp_contexts中，系统将把seinfo作为一个key来决定给某些App分配特殊的标签。这个文件将在system_server启动时被加载读取。
- seapp_contexts

这个文件用于为App进程和/data/data文件夹指定标签。系统读取

seapp_contexts的时机为：

（1）当一个App在zygote进程中被启动时；

（2）当installd在启动时；

（3）当selinux.reload_policy属性被置为1时。

另外，Android系统也允许各设备商定制自己的安全策略。如果大家有需要的话，可以参见/device/lge/hammerhead/BoardConfig.mk中的例子。这个编译脚本中包含了若干以BOARD_SEPOLICY开头的变量，用于指明厂商的自定义规则。如下所示：

```
BOARD_SEPOLICY_DIRS += \
       device/lge/hammerhead/sepolicy

# The list below is order dependent
BOARD_SEPOLICY_UNION += \
       app.te \
       bluetooth_loader.te \
       bridge.te \
       camera.te \
       device.te \
       domain.te \
       file.te \
       hostapd.te \
       irsc_util.te \
       mediaserver.te \
       mpdecision.te \
       netmgrd.te \
       platform_app.te \
       qmux.te \
       radio.te \
       rild.te \
       rmt.te \
       sensors.te \
       ssr.te \
       surfaceflinger.te \
       system_server.te \
       tee.te \
       thermald.te \
```

大家可以阅读后续小节，学习针对policy定制的更多详细信息。

22.4.3　SEAndroid标签和规则

标签（label）是SEAndroid机制的基础，它用于为策略和行为提供匹配条件。Android系统中的任何资源（包括Socket、文件、进程等）都有自己对应的标签。

标签的基本格式是：

```
user:role:type:mls_level
```

各属性释义如下：

- User
- 在SEAndroid中User代表用户，而且到目前为止的可选值只有“u”一种（有可能是预留的属性）。
- 如下是/system/sepolicy/users文件中的内容：

```
user u roles { r } level s0 range s0 - mls_systemhigh;
```

- Role
- 在SEAndroid中代表角色。和User类似，这个属性的可选值也比较固定：对于主体来说是r,对于客体来说则是object_r。
- 下面是/system/sepolicy/roles中的内容：

```
role r;
role r types domain;
```

- 其中“role r”声明了一个名为r的角色；而“role r types domain”则表示它是与domain（主体Type）相关联的，见下面一项的说明
- Type
- SEAndroid中定义了超过130种的Type类型，比如device type、process type（又被称为domain）、file system type、network type、IPC type等。
- 下面是/system/sepolicy/domain.te中的部分内容：

```
\# Rules for all domains. \# Allow reaping by init. allow domain
```

```
init:process sigchld; \# Read access to properties mapping. allow domain kernel:fd use; allow domain tmpfs:file { read getattr }; \# Search /storage/emulated tmpfs mount. allow domain tmpfs:dir r_dir_perms; \# Intra-domain accesses. allow domain self:process {
    fork    sigchld    sigkill    sigstop    signull
signal    getsched    setsched    getsession    getpgid
    setpgid    getcap    setcap    getattr    setrlimit };
```

- Security level(Multiple Level Security) MLS的格式为：[: category list] [- sensitivity [: category list]] 在Android系统的Type Enforment中，4个标签属性中只有Type才是决定安全策略执行结果最重要的考量参数，所以我们可以在分析过程中有所侧重，有针对性地提高效率。 ### 22.4.4 如何在Android系统中自定义SEAndroid 本小节我们将介绍Android系统应用SEAndroid需要做哪些工作，以及各设备厂商如何才能自定义安全规则。 Step1. 在内核中开启SELinux支持。 对应的变量如下所示：

```
CONFIG_SECURITY_SELINUX=y
```

Step2. 修改内核启动参数，具体来说是在Android工程中添加如下的命令行：

```
BOARD_KERNEL_CMDLINE := androidboot.selinux=permissive
```

Step3. 以permisive模式启动系统，然后可以看到在启动过程中会遇到哪些denials。

在Ubuntu 14.04及以后：

```
adb shell su -c dmesg | grep denied | audit2allow -p
out/target/product/board/root/sepolicy
```

在Ubuntu 12.04：

```
adb shell su -c dmesg | grep denied | audit2allow
```

Step4. 评估上一步中的输出结果。

SELinux的log消息都包含了“avc:”字符串，因而可以很容易地找到。

通过这一评估结果，我们可以知道目前有哪些违反规则的行为，然后有针对性地进行更正。如下是一个典型的例子：

```
avc: denied { connectto } for pid=2671 comm="ping"
path="/dev/socket/dnsproxyd"
scontext=u:r:shell:s0 tcontext=u:r:netd:s0
tclass=unix_stream_socket
```

其中{ connectto }代表的是发生的形为。整个句子表示有人尝试去连接一个unix stream socket。

参数scontext代表的是发起上述形为的主体的具体环境。在这个例子中就是某个以shell运行的程序。

参数tcontext是客体的具体环境。在这个例子中就是一个unix_stream_socket的所有者netd。

而comm=”ping”表示的是当denial发生时究竟执行了什么语句。

Step5. 鉴别出哪些设备或者其他新增文件需要添加Label。

Step6. 使用现存的或者新增的labels为客体添加标签。可以借鉴工程中的*_contexts文件来看一下别人是怎么做的，包括如何新增标签。如下例子所示：

```
##############################################
# Root
/       u:object_r:rootfs:s0

# Data files
/adb_keys    u:object_r:adb_keys_file:s0
/default\.prop     u:object_r:rootfs:s0
/fstab\..*     u:object_r:rootfs:s0
/init\..*    u:object_r:rootfs:s0
/res(/.*)?     u:object_r:rootfs:s0
/ueventd\..*     u:object_r:rootfs:s0

# Executables
/charger     u:object_r:rootfs:s0
/init      u:object_r:rootfs:s0
/sbin(/.*)?    u:object_r:rootfs:s0

# Empty directories
/lost\+found     u:object_r:rootfs:s0
/proc      u:object_r:rootfs:s0
```

Step7. 为系统中的所有由init启动的services(process或daemon)分配一个自己的domain。

如何识别出这些services呢？官方推荐了几种方法：

（1）从init.<device>.rc文件中获取

（2）检查dmesg输出中所有与“init: Warning! Service name needs a SELinux domain defined; please fix!”相关的语句

（3）通过ps -Z | grep init来检查有哪些service是以init domain来运行的，如图22-17所示；

```
shell@hwmt7:/ $ ps -Z |grep init
ps -Z |grep init
u:r:init:s0                    root      1     0     /init
u:r:kernel:s0                  root      1229  2     rdr_init_thread
u:r:init:s0                    root      2402  1     /sbin/oeminfo_nvm_server
u:r:init:s0                    system    2420  1     /system/bin/servicemanager
u:r:init:s0                    root      2421  1     /system/bin/vold
u:r:init:s0                    root      2423  1     /system/bin/netd
u:r:init:s0                    root      2424  1     /system/bin/debuggerd
u:r:init:s0                    radio     2425  1     /system/bin/rild
u:r:init:s0                    system    2426  1     /system/bin/surfaceflinger
u:r:init:s0                    root      2427  1     zygote
u:r:init:s0                    drm       2428  1     /system/bin/drmserver
u:r:init:s0                    root      2429  1     /system/bin/filebackup
u:r:init:s0                    media     2430  1     /system/bin/mediaserver
u:r:init:s0                    install   2431  1     /system/bin/installd
u:r:init:s0                    keystore  2432  1     /system/bin/keystore
u:r:init:s0                    root      2433  1     /system/bin/hwpged
u:r:init:s0                    root      2434  1     /system/bin/thermal-daemon
u:r:init:s0                    system    2436  1     /system/bin/logserver
u:r:init:s0                    root      2437  1     /system/bin/hw_ueventd
u:r:init:s0                    root      2438  1     /system/bin/diagserver
u:r:init:s0                    root      2441  1     /system/bin/hwnffserver
u:r:init:s0                    root      2442  1     /system/bin/device_monitor
```

▲图22-17　以init domain运行的进程

（4）通过如下命令查看是否还有其他需要注意的遗漏项：

```
$ adb shell su -c dmesg | grep 'avc: '
```

Step8. 在BOARD_CONFIG.mk中为BOARD_SEPOLICY_*赋值。这点我们在前面小节已经提到过了。

Step9. 检查init.<device>.rc和fstab.<device>来确保所有“mount”使用的都是已经正确添加了标签的文件系统，或者已经指定了context=mount选项。

Step10. 书写安全策略来确保所有被限制的权限都可以得到合理的管理。这一步我们将在下一小节中做展开讨论。

22.4.5　TE文件的语法规则

我们接着前一小节的步骤，讲解一下安全策略的书写与注意事项。

在SEAndroid中，安全策略文件通常以.te为后缀名，比如adbd.te、app.te、Bluetooth.te、device.te等。厂商自定义的te文件建议放置在/device/manufacture/[device-name]/sepolicy文件夹下，并通过BOARD_SEPOLICY变量来将它们添加到编译环境中，以保证安全策略可以被正确纳入到系统中加以实施。

在自定义安全策略的过程中，有如下几个注意事项：

- 切记不要删除目前已有的安全策略文件。建议各个厂商根据自己的实际需要，新增针对某些资源的保护策略；
- 为所有新增的daemons新增安全策略；
- 在合适的情况下，尽量使用已经定义过的domain；
- 对于从init中启动的任何进程，都确保它有独立于init的domain；
- 在书写安全策略前，先要了解清楚它的规则，多参考别人已有的范例；
- 在可能的情况下，将核心策略提交给AOSP工程组。

另外，以下是Android官方给出的“Not to do list”：

- 创建一个不兼容的安全策略；
- 允许终端用户自定义安全策略；
- 允许MDM策略的自定义；
- 让用户感觉处处都充满了策略违规行为，造成很差的用户体验；
- 添加后门。

可以参考以下文章中关于安全特性要求的详细描述：

https://static.googleusercontent.com/media/source.android.com/zh-CN//compatibility/android-cdd.pdf。

还有一点也是我们反复强调的，即一开始在调试阶段可以只开启permissive模式，来找出当前系统中还存在哪些问题，然后不断迭代地解决这些问题，最终在量产时再开启强制模式。

在前述Label的基础上，Policy的基本格式是：

```
allow domains types:classes permissons:
```

上述格式中的几个关键字的释义如下：

- Domain
- 用于标识单一进程或一系列进程。
- Type

用于标识客体（文件、Socket等）或一系列客体。

- Class

被访问的客体（文件、Socket等）的具体种类。

- Permission

可以被允许的操作（读、写等）

除了上述规则格式所提到的关键词外，我们还可以通过属性（attribute）来指定domain或者Type——它们都可以与任意数量的attribute相挂钩。换句话说，当一条规则是通过attribute来书写的话，那么系统将自动把其中的attribute解析成具体的domains和Types。

举个例子来说，如下的一条策略：

```
allow domain null_device:chr_file { open };
```

这条策略允许与属性值domain相关联的进程可以打开“Type为null_device，class为chr_file”的客体。值得一提的是，null_device用于标识/dev/null设备。

下面我们以adbd.te为例讲解一下如何书写一个合格的安全策略文件。

```
//Note 1:
allow adbd shell:process noatsecure;
```

```
//Note 2:
allow adbd self:capability { setuid setgid };
//Note 3:
net_domain(adbd)
//Note 4:
allow adbd adb_device:chr_file rw_file_perms;
allow adbd functionfs:dir search;
allow adbd functionfs:file rw_file_perms;
//Note 5:
allow adbd devpts:chr_file rw_file_perms;
//Note 6:
allow adbd shell_data_file:dir create_dir_perms;
allow adbd shell_data_file:file create_file_perms;
//Note 7:
allow adbd sdcard_type:dir create_dir_perms;
allow adbd sdcard_type:file create_file_perms;
//Note 8:
allow adbd anr_data_file:dir r_dir_perms;
allow adbd anr_data_file:file r_file_perms;
//Note 9:
allow adbd system_file:file rx_file_perms;
//Note 10:
binder_use(adbd)
binder_call(adbd, surfaceflinger)
allow adbd gpu_device:chr_file rw_file_perms;
//Note 11:
allow adbd adb_keys_file:dir search;
allow adbd adb_keys_file:file r_file_perms;
```

首先要说的是，SEAndroid安全策略文件使用的是M4语言，因而支持一系列预定义的宏。大家可以参考如下官方网站了解详情：

```
https://www.gnu.org/software/m4/manual/index.html
```

我们在前面小节提到过，TE文件的基本语句格式如下：

```
allow domains types:classes permissons:
```

接下来针对上面的adbd.te具体分析一下。

Note 1：这条语句比较特殊，它表明不能对shell的环境做净化（sanitize）或者打开shell的fds。为了让大家更好地理解noatsecure，我们首先要知道什么是atsecure。

当一个应用程序初始化另一个程序时，它首先执行fork，然后通过execve来把程序加载到内存中——后面这一加载动作通常是由binary loader完成的，在Linux中对应的是ELF Loader。而ELF auxiliary vectors则是由loader设置的一系列参数，它们为应用程序提供了与操作系统相关的特殊信息。比如AT_SECURE。这个参数用来告诉ELF动态链接器unset一些可能会对系统产生潜在威胁的环境变量，如LD_PRELOAD。所以简而言之，noatsecure将关闭对环境的净化功能。

Note 2：允许adbd对shell执行setuid和setgid。

Note 3：创建并使用网络Sockets。

Note 4：允许访问/dev/android_adb和/dev/usb-ffs/adb/ep0。

这是因为adb_device对应的是/dev/android_adb.*，定义在file_contexts中：

```
/dev/android_adb.*  u:object_r:adb_device:s0
```

Note 5：允许使用一个虚拟tty。

Note 6：允许adb pull/push指定的文件夹：/data/local/tmp，定义如下：

```
/data/local/tmp(/.*)? u:object_r:shell_data_file:s0
```

Note 7：允许adb pull/push sdcard。

Note 8：允许adb pull指定文件夹：/data/anr/traces.txt，因为只有read的权限。

Note 9：允许运行/system/bin/bu。

Note 10：允许与surfaceflinger进行binder的IPC通信。

Note 11：允许读取/data/misc/adb/adb_keys。

22.4.6 SEAndroid中的核心主体——init进程

SEAndroid Subject的载体是进程，换句话说设备中运行的绝大部分进程都应该是和安全上下文相关联的，这样才能保证系统在判断它们是否具有访问客体权限时“有据可依”。

我们知道，init是Android系统运行的第一个进程，包括程序孵化器——Zygote在内的所有后续进程都是由它直接或间接启动的。可想而知，SEAndroid对系统的实时保护也一定和init有关联——例如policy文件的加载就是在init中进行的。另外init本身也是系统中的一个进程，因而本小节将以它作为SEAndroid的主体代表来进行详细剖析。

init程序对应的源码目录是/system/core/init。我们首先看一下它的main函数中与SELinux相关的实现：

```
/*system/core/init*/
int main(int argc, char **argv)
{
    …
    selinux_initialize(is_first_stage);
```

由此可见，init进程的main函数是系统初始化和启用SELinux的起点，其中selinux_initialize的核心实现如下：

```
/*system/core/init/init.cpp*/
static void selinux_initialize(bool in_kernel_domain) {
    Timer t;

    selinux_callback cb;
    cb.func_log = selinux_klog_callback;
    selinux_set_callback(SELINUX_CB_LOG, cb);
    cb.func_audit = audit_callback;
    selinux_set_callback(SELINUX_CB_AUDIT, cb);

    if (in_kernel_domain) {
        INFO("Loading SELinux policy...\n");
```

```
        if (selinux_android_load_policy() < 0) {
            ERROR("failed to load policy: %s\n", strerror(errno))
            security_failure();
        }
        …
    } else {
        selinux_init_all_handles();
    }
}
```

在N版本之前，init进程会通过selinux_is_disabled来判断当前SELinux是否被禁用了——此时存在如下两种可能的情况：

Case 1：/sys/fs/selinux无法访问，这很可能是SELinux没有编译进内核中，或者通过内核命令参数“selinux=0”关闭了

Case 2：系统属性ro.boot.selinux的值为disabled。

紧接着的重点是selinux_callback，它的源码实现在selinux.h中：

```
/*external/libselinux/include/selinux*/
/* Callback facilities */
union selinux_callback {
    /* log the printf-style format and arguments,
       with the type code indicating the type of message */
    int
#ifdef __GNUC__
__attribute__ ((format(printf, 2, 3)))
#endif
    (*func_log) (int type, const char *fmt, ...);
    /* store a string representation of auditdata (corresponding
       to the given security class) into msgbuf. */
    int (*func_audit) (void *auditdata, security_class_t cls,
                char *msgbuf, size_t msgbufsize);
    /* validate the supplied context, modifying if necessary */
    int (*func_validate) (char **ctx);
    /* netlink callback for setenforce message */
    int (*func_setenforce) (int enforcing);
    /* netlink callback for policyload message */
    int (*func_policyload) (int seqno);
};
```

可以看到，selinux_callback是一个union数据结构，在调用时需

要同时指定所针对的是哪种类型的回调，如下所示。

- SELINUX_CB_LOG: (*func_log) (int type, const char *fmt, ...)

  回调log信息，并通过type指示log类型。

- SELINUX_CB_AUDIT: int (*func_audit) (void *auditdata, security_class_t cls,

  char *msgbuf, size_t msgbufsize)

  将auditdata中的数据以一定格式保存到msgbuf中。

- SELINUX_CB_VALIDATE: int (*func_validate) (char **ctx)

  验证ctx这个安全上下文环境。

- SELINUX_CB_SETENFORCE: int (*func_setenforce) (int enforcing)

  用于setenforce消息的回调。

- SELINUX_CB_POLICYLOAD: int (*func_policyload) (int seqno)

  用于安全策略加载时的回调。

上述的selinux_initialize函数中设置了两个回调函数，即log_callback和audit_callback。

接下来初始化函数将继续运行并加载安全策略。我们在前面小节已经讲解过，这些安全策略是专门为Android系统设计的，因而它的实现是在android.c中：

```
/*external/libselinux/src/android.c*/
int selinux_android_load_policy(void)
{
     int fd = -1, rc;
     struct stat sb;
     void *map = NULL;
     static int load_successful = 0;
     if (load_successful){//已经加载过policy了
```

```
        selinux_log(SELINUX_WARNING, "SELinux: Attempted reload of
        return 0;
      }

      set_selinuxmnt(SELINUXMNT);
      fd = open(sepolicy_file, O_RDONLY | O_NOFOLLOW | O_CLOEXEC);
      …
      if (fstat(fd, &sb) < 0) {
           selinux_log(SELINUX_ERROR, "SELinux:  Could not stat %s
                     sepolicy_file, strerror(errno));
           close(fd);
           return -1;
      }
      map = mmap(NULL, sb.st_size, PROT_READ, MAP_PRIVATE, fd, 0);
      …
      rc = security_load_policy(map, sb.st_size);
      …
      munmap(map, sb.st_size);
      close(fd);
      selinux_log(SELINUX_INFO, "SELinux: Loaded policy from %s\n"
      load_successful = 1;
      return 0;
}
```

在Android N版本之前，系统首先会尝试mount selinux的结点SELINUXMNT，即“/sys/fs/selinux”。如果这一步失败的话，又有两种可能性：

Case 1: errno ==ENODEV

设备不存在，这种情况下说明SELinux在系统中没有被启用，因而直接返回错误码

Case 2:errno == ENOENT

目录不存在，此时需要新建一个SELINUXMNT文件夹。如果mkdir仍然失败，则直接返回错误;否则重试上面的mount操作。

假如mount成功，我们紧接着就需要先保存当前的挂载节点，即set_selinuxmnt(mnt)。这个函数会把mnt的值存储到通过strup重新分配的一个字符串，然后让selinux_mnt指向它。变量selinux_mnt是全局的，用于实时存储运行过程中的SElinux挂载点。

Android N版本中的处理方式发生了一些变化，简单来说就是不支持动态重加载policy了。所以可以看到selinux_android_load_policy通过load_successful变量来判断系统是否已经加载过安全策略了，如果答案是肯定的话，函数会直接返回。

接着尝试打开策略文件sepolicy_file。在Android N版本之前，它是一个数组，定义如下：

```
static const char *const sepolicy_file[] = {
     "/sepolicy",
     "/data/security/current/sepolicy",
     NULL };
```

变量policy_index的初始值为0，但是会随着set_policy_index的调用而可能产生变化。

Android N版本中的情况则更为简单，即sepolicy_file只代表“/sepolicy”一种可能了。

如果open成功的话，将接着执行fstat。这个函数的作用是获取文件的当前状态，并把结果存储到stat数据结构（上述代码中对应的是sb变量）中。

如果上面步骤执行正常的话，我们就可以开始内存映射mmap了，即将fd描述的文件映射到sb.st_size。注意mmap的第一个参数给的是NULL，然后通过函数返回值将指针传递给map变量。一切准备就绪后，函数接着执行security_load_policy：

```
/*external/libselinux/src/load_policy.c*/
int security_load_policy(void *data, size_t len)
{
     char path[PATH_MAX];
     int fd, ret;

     if (!selinux_mnt) {
          errno = ENOENT;
          return -1;
     }

     snprintf(path, sizeof path, "%s/load", selinux_mnt);
     fd = open(path, O_RDWR);
     if (fd < 0)
```

```
        return -1;

    ret = write(fd, data, len);
    close(fd);
    if (ret < 0)
        return -1;
    return 0;
}
```

可以看到，这个函数主要是通过snprintf来组成一个新的路径（即在selinux_mnt的尾部加上“/load”），并将这个path指示的文件打开，然后把data（即“/sepolicy”安全策略文件）中的内容写入到路径中。概括来说，就是把Android的策略文件通过SELinux的挂载点写入到内核中。

执行完上述函数和selinux_android_load_policy后，我们回到selinux_initialize中继续分析。如果加载策略失败的话，说明当前系统出现了非常严重的问题，因而设备将直接重启并进入recovery模式。

如果策略加载成功，接下来还需要初始化sehandle，然后调用security_setenforce将系统的SELinux设置为合适的状态，即：

如果系统属性ro.boot.selinux没有设置或者为enforcing，进入enforcing状态；否则，如果ro.boot.selinux等于permissive，则进入自由模式：

```
/*external/libselinux/src/setenforce.c*/
int security_setenforce(int value)
{
    int fd, ret;
    char path[PATH_MAX];
    char buf[20];

    if (!selinux_mnt) {
        errno = ENOENT;
        return -1;
    }

    snprintf(path, sizeof path, "%s/enforce", selinux_mnt);
    fd = open(path, O_RDWR);
    if (fd < 0)
        return -1;
```

```
    snprintf(buf, sizeof buf, "%d", value);
    ret = write(fd, buf, strlen(buf));
    close(fd);
    if (ret < 0)
        return -1;

    return 0;
}
```

由上述代码段可知函数security_setenforce和前面讲解的security_load_policy是类似的，均是通过向selinux_mnt下的文件写入数据来与内核中的SELinux进行通信。这样一来我们就把Android上层的安全策略成功写入到Linux的LSM模块中，并设置了正确的防护模式了，如图22-18所示。

```
shell@hwmt7:/sys/fs/selinux $ ls -l
ls -l
-rw-rw-rw- root     root              0 1970-01-01 01:00 access
dr-xr-xr-x root     root                1970-01-01 01:00 avc
dr-xr-xr-x root     root                1970-01-01 01:00 booleans
-rw-r--r-- root     root              0 1970-01-01 01:00 checkreqprot
dr-xr-xr-x root     root                1970-01-01 01:00 class
--w------- root     root              0 1970-01-01 01:00 commit_pending_bools
-rw-rw-rw- root     root              0 1970-01-01 01:00 context
-rw-rw-rw- root     root              0 1970-01-01 01:00 create
-r--r--r-- root     root              0 1970-01-01 01:00 deny_unknown
--w------- root     root              0 1970-01-01 01:00 disable
-rw-r--r-- system   system            0 1970-01-01 01:00 enforce
dr-xr-xr-x root     root                1970-01-01 01:00 initial_contexts
-rw------- system   system            0 1970-01-01 01:00 load
-rw-rw-rw- root     root              0 1970-01-01 01:00 member
-r--r--r-- root     root              0 1970-01-01 01:00 mls
crw-rw-rw- root     root         1,   3 1970-01-01 01:00 null
-r--r--r-- root     root              0 1970-01-01 01:00 policy
dr-xr-xr-x root     root                1970-01-01 01:00 policy_capabilities
-r--r--r-- root     root              0 1970-01-01 01:00 policyvers
-r--r--r-- root     root              0 1970-01-01 01:00 reject_unknown
-rw-rw-rw- root     root              0 1970-01-01 01:00 relabel
-r--r--r-- root     root              0 1970-01-01 01:00 status
-rw-rw-rw- root     root              0 1970-01-01 01:00 user
```

▲图22-18　/sys/fs/selinux文件结构

从本小节的分析大家应该不难发现，init程序向SELinux设置的policy策略通常情况下就来源于设备根目录下的sepolicy文件，而后者又是由AOSP工程下的/enternal/sepolicy的各种.te编译而成的。

那么init进程自身的安全上下文是什么呢？

在Android旧版本中，它是在init.rc中通过setcon接口直接指定的;目前版本中的实现则略为复杂，会把init拆分成两个阶段。

Stage1:

此时init进程运行在kernel domain中，同时selinux_initialize的函数入参in_kernel_domain为true，所以说前述的安全策略的加载过程就是在这一阶段完成的。

在执行完第一阶段的selinux_initialize后，init进程的main函数会re-exec程序，并人为地添加一个参数“--second-stage”，从而进入第二阶段。

Stage2:

此时in_kernel_domain为false，并且init进程运行于init domain下。

另外，init文件的安全上下文关联是由restorecon("/init")完成的，对应的源码如下所示：

```
/*system/core/init/init.cpp*/
if (is_first_stage) {
        if (restorecon("/init") == -1) {
            ERROR("restorecon failed: %s\n", strerror(errno));
            security_failure();
        }
```

函数restorecon会在system/sepolicy/file_contexts提供的信息中（注意：file_contexts会和其他策略一起放在设备的/sepolicy文件里）去查找上述指定的路径，最终匹配到如下内容：

```
/init               u:object_r:init_exec:s0
```

也就是说init文件的type是init_exec（可执行文件）。

除了init外，系统中还运行着很多其他的进程，例如zygote(app_process)、各应用程序进程等。读者可以在本小节的基础

上自行分析它们的安全上下文是如何完成关联操作的。

22.4.7 SEAndroid中的客体

SEAndroid中的客体包括系统文件、应用程序文件、系统属性等很多被保护的资源对象。为了简化分析，本小节我们以应用程序文件为例来讲解一下它们是如何关联安全上下文的。

与系统文件这类预置的资源不同（系统文件主要由file_contexts来设定安全上下文），应用程序的文件多数是在程序安装或者运行过程中才会产生，而且用户设备将要安装哪些应用程序事先是未知的，所以针对它们的处理方式也需要更加灵活。

我们知道，应用程序专有的数据存储目录在/data/data中，因而问题自然而然地转化为：这个目录下的文件夹和文件是如何关联安全上下文的呢？进一步来讲，它们又是由PackageManagerService和installd在应用程序的安装过程中创建的，所以需要重点关心的就是这两个系统服务了。

应用程序的具体安装过程在本书其他章节已经有过详细分析，这里不再赘述。我们只要知道PMS会调用installer.java中的install接口来发起一个安装过程就可以了，原型如下所示：

```
public int install(String uuid, String name, int uid, int gid, St
```

大家应该注意到了最后一个函数参数seinfo，它是PMS通过前面小节曾讲解过的system/sepolicy下的专门文件mac_permissions.xml来获取的（应用程序签名和seinfo有对应的映射关系）。

系统服务installd将响应PMS的安装请求，并通过selinux_android_setfilecon来为应用程序的data目录设置上下文安全环境，实现如下：

```
/*external/libselinux/src/Android.c*/
int selinux_android_setfilecon(const char *pkgdir,
                    const char *pkgname,
                    const char *seinfo,
                    uid_t uid)
{
     char *orig_ctx_str = NULL;
```

```
	char *ctx_str = NULL;
	context_t ctx = NULL;
	int rc = -1;

	if (is_selinux_enabled() <= 0)//SELinux是否开启
		return 0;

	rc = getfilecon(pkgdir, &ctx_str);
	if (rc < 0)
		goto err;

	ctx = context_new(ctx_str);
	orig_ctx_str = ctx_str;
	if (!ctx)
		goto oom;

	rc = seapp_context_lookup(SEAPP_TYPE, uid, 0, seinfo, pkgnam
	if (rc == -1)
		goto err;
	else if (rc == -2)
		goto oom;

	ctx_str = context_str(ctx);
	if (!ctx_str)
		goto oom;

	rc = security_check_context(ctx_str);
	if (rc < 0)
		goto err;

	if (strcmp(ctx_str, orig_ctx_str)) {
		rc = setfilecon(pkgdir, ctx_str);
		if (rc < 0)
			goto err;
	}

	rc = 0;
out:
	freecon(orig_ctx_str);
	context_free(ctx);
	return rc;
err:
	selinux_log(SELINUX_ERROR, "%s:  Error setting context for p
		    __FUNCTION__, pkgdir, uid, strerror(errno));
	rc = -1;
	goto out;
oom:
	selinux_log(SELINUX_ERROR, "%s:  Out of memory\n", __FUNCTIO
```

```
        rc = -1;
        goto out;
}
```

libselinux是对SELinux的上层封装，以使程序可以非常方便地使用SELinux机制。在上述这个函数中，我们首先判断当前是否已经开启了SELinux安全机制，只有在答案是肯定的情况下，才需要执行下一步操作。紧接着的getfilecon是获取目录路径的当前安全上下文(目录的默认安全上下文将继承自它的父目录)，并将其保存在ctx_str变量中。有了这个基础后，再创建新的context就有依据了——前后两个context最大的不同在于Type，而新的Type值则由seapp_context_lookup来负责获取。

最后，如果两个context之间存在差异的话(strcmp不等于0)，那么我们就调用setfilecon来为应用程序的目录设置新的环境，从而完成它的安全上下文关联。

22.5 Android设备Root简析

如何获取Root权限是Android中一个老生常谈的话题。Root这个词虽然大家都耳熟能详，但是究竟应该如何定义它呢？从系统设计的角度来看，Root是一个“名词”，它代表的是一个操作系统（如Linux）的最高权限用户（Superuser）。Linux操作系统中，不同user针对同一个文件的操作权限是有区别的，而Root则拥有至高无上的权利——理论上讲它对任何文件都具有“生杀予夺”（注意：在开启了SEAndroid的设备上，Root的权限受到了限制）的大权。也因为它的权利过大，所以通常情况下用户将以普通的权限来运行系统，后者则会被加以各种强制约束。

Android操作系统虽然没有用户登录的概念，但却也有UID的存在。而除了系统开始时短暂的“放权”外，所有后续启动的应用程序都只有非常有限的普通权限。由此就引申出了Root的动词用法，即“获取Root权限”。“道高一尺，魔高一丈”，Root技术总是要随着Android系统的更新换代而“天天向上”。

目前市面上已知的Root手段既有手工的，也有各种“××一键Root”之类的便捷工具。不过，大家应该知道，并非所有Android设备都可以被轻松Root。这一方面和Android版本有　　　关——通常情况下版本越高，Root的难度也越大。这同时也说明了Android项目在安全性保护方面也在日趋成熟。另一方面，一些设备厂商们为了更好地保护用户的利益，也会对产品实施“刷机加锁”（比如华为系列手机就有类似的保护）。这就意味着各位发烧友们可能需要先进行解锁操作后，才有办法实施各种Root方案。当然，很多大的设备厂商也会提供专门的渠道来帮助确实有需要的用户完成加解锁操作，例如华为EMUI提供的官方网址如下：

http://emui.huawei.com/cn/plugin.php?id=unlock&mod=detail

那么如何才能越过系统设置的重重障碍，获取到Root权限呢？我们就以曾经风靡一时的“adbd提权”为例，为大家阐释一下利用系统漏洞达到“非法”手段的大致原理。

不过在讲解这个Root手法之前，我们有必要先补充一些基础知识。

相信做过Android开发的人都清楚，Android原生模拟器默认情况下提供的就是Root权限。我们可以通过adb shell来针对模拟器做一下验证，如下所示：

为什么模拟器中的shell可以获取到Root权限呢？原因就在于系统属性的配置。我们知道，adb最终是通过设备中的adbd来完成任务的，而adbd的父进程其实就具有Root权限。当adbd启动后，会调用如下的函数来判断是否要主动降低权限：

```
/*system/core/adb/adb.c*/
static int should_drop_privileges() {
#ifndef ALLOW_ADBD_ROOT
    return 1;
#else /* ALLOW_ADBD_ROOT */
    int secure = 0;
    char value[PROPERTY_VALUE_MAX];
    property_get("ro.kernel.qemu", value, "");
    if (strcmp(value, "1") != 0) {
        property_get("ro.secure", value, "1");
        if (strcmp(value, "1") == 0) {
            // don't run as root if ro.secure is set...
            secure = 1;
            property_get("ro.debuggable", value, "");
            if (strcmp(value, "1") == 0) {
                property_get("service.adb.root", value, "");
                if (strcmp(value, "1") == 0) {
                    secure = 0;
                }
            }
        }
    }
    return secure;
#endif /* ALLOW_ADBD_ROOT */
}
```

上面这段代码的逻辑是：如果没有定义ALLOW_ADBD_ROOT，那么就直接返回1，表示需要降权。否则接着判断系统属性“ro.kernel.qemu”，如果值为1表示当前是qemu模拟器，那么就直接返回0，表示不要降低权限；如果当前不是模拟器也仍然有机会获取到Root权限——不过必须满足“ro.secure”没有被置为1，或者当前是

可调试状态（“ro.debuggable”为1）且“service.adb.root”为1。

状态梳理图如图22-19所示。

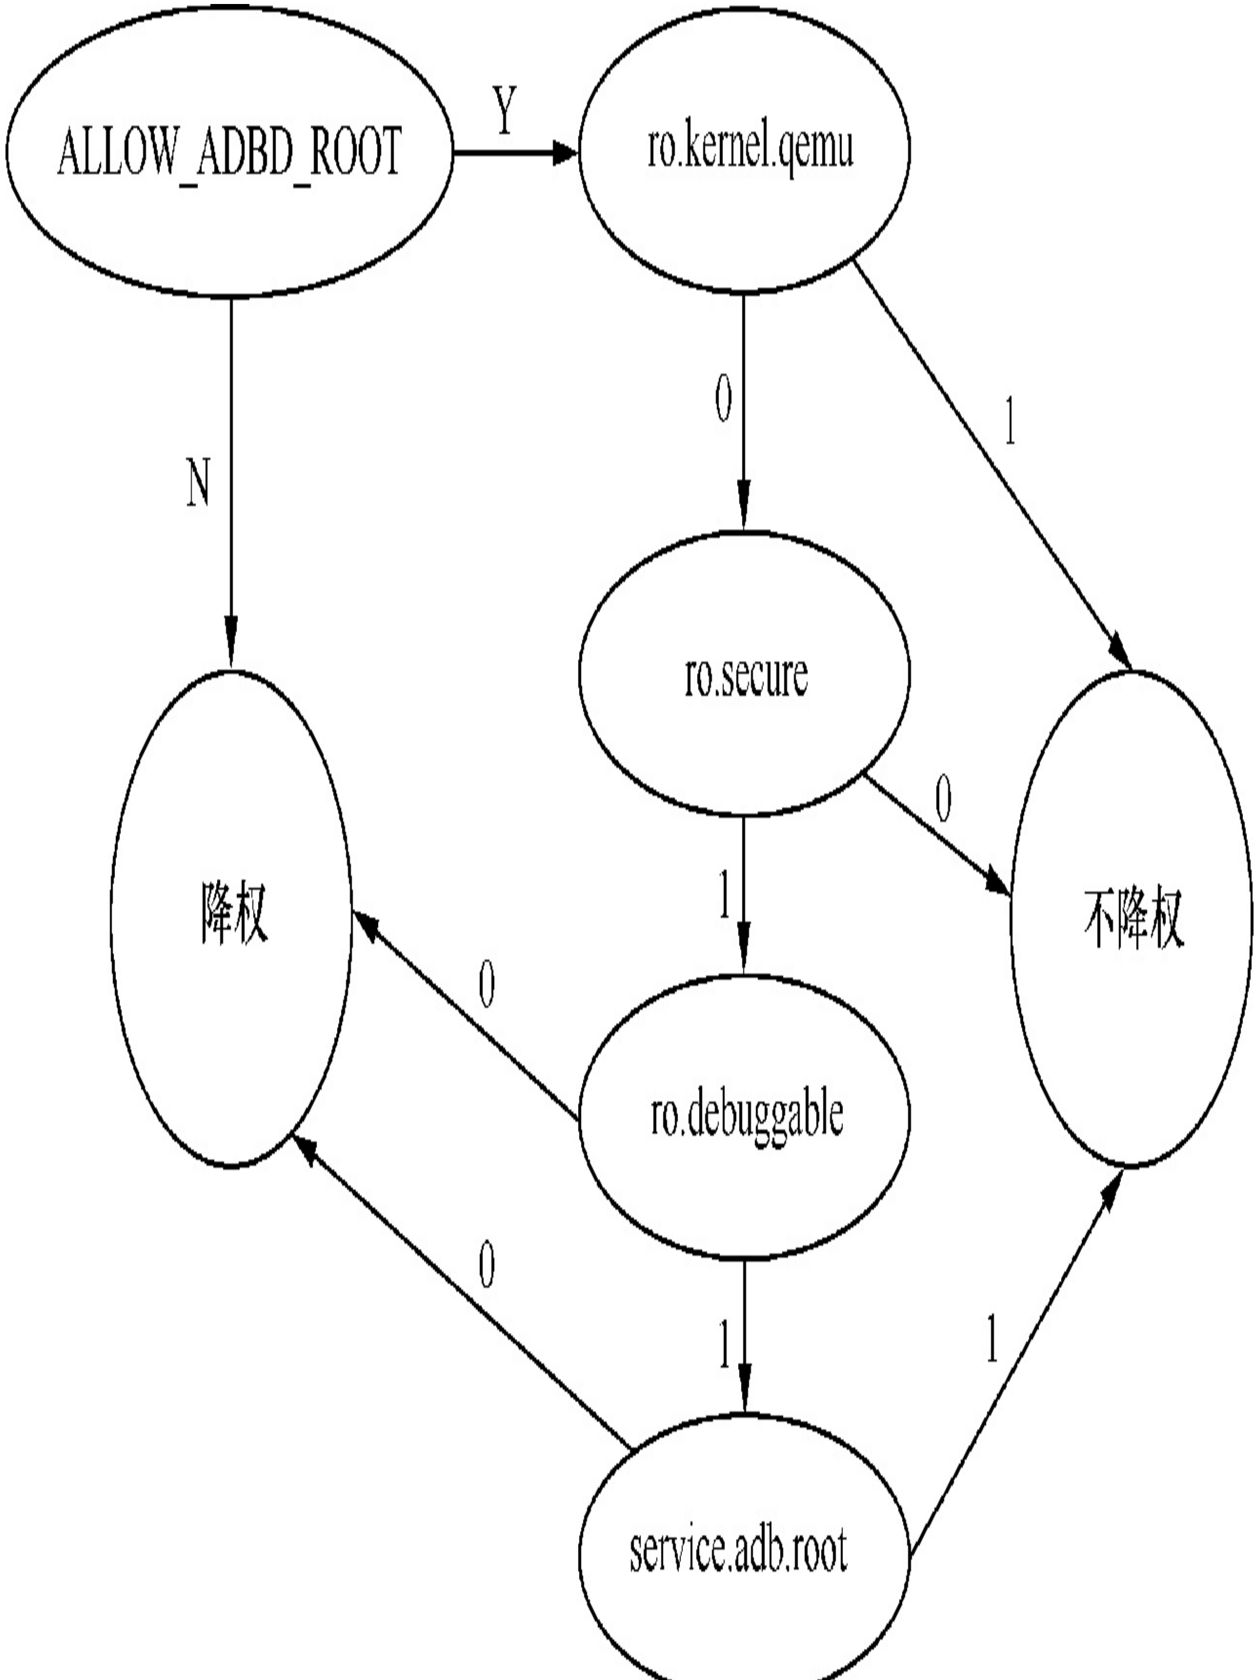
ALLOW_ADBD_ROOT
Y
ro.kernel.qemu
N
0
1
ro.secure
0
降权
1
不降权
0
ro.debuggable
0
1
1
service.adb.root

▲图22-19　adbd是否需要降权的判断逻辑

也就是说，adbd在一开始时是以Root权限来运行的，并且会在后期利用should_drop_privileges的返回结果来判断自己是否需要执行降权操作。对这个过程的梳理给了我们至少如下两点启发：

- 如果在真机设备中，should_drop_privileges也可以像模拟器中的情况那样返回0，那么adbd或许就会一直以Root权限来运行了；
- 即便是should_drop_privileges本身返回1，但是adbd在执行降权操作时失败了，那么它也可能会一直以Root权限来运行了。

上述这两条其实就是早期Android版本中adbd提权的重要依据，很多Root手法就是利用它们来达到目的的。譬如有一个研究小组，就使用了一种巧妙的手法来让adbd的降权操作失败——首先，在系统中产生足够多的shell用户僵尸进程；然后强制结束掉原有的adbd进程，迫使它被重启。因为内核对于用户可以运行的进程数量是有限制的，所以adbd在切换到shell身份时就会遭遇失败。再加上早先Android版本对此并没有做必要的处理，最终得到的结果就是adbd会以Root身份来一直运行，我们的目标也就达到了。

除此之外，Root过程还有很多常用的手法，例如利用栈溢出来执行非法操作；利用“0地址”造就特殊的函数调用等。

一旦有可控的程序获取到了Root权限后，接下来我们还可以执行如下几步操作。

Step1. 将su程序放置到/system/bin下。

Step2. 将Superuser.apk（或者其他管理者程序）放置到/system/app下。

Step3. 管理权限申请。

这样做的目的是方便我们对Root权限进行管理。举个例子来说，如果系统本身已经被Root，那么也可以通过下面的方法来为adbd提取：

```
D:\game>adb shell
shell@Lan779:/ $ su
shell@Lan779:/ #
```

这种方式需要得到系统中Root管理者的批准，Android系统中最有名的Root管家是Superuser，界面如图22-20所示。

其他应用程序在已Root设备上的提权过程也是类似的。

了解了adbd的提权示例后，我们再来讨论下如何在程序中判断当前设备是否被Root过？

▲图22-20　界面

典型的方法有两种，其一是读取/system/bin/或者/system/xbin目录下是否存在su程序；其二就是直接执行su程序并观察执行情况，范例如下：

```
Runtime.getRuntime().exec("su");
```

当然，这两种方法都可能有缺陷，并不能保证100%的准确性。不过对于大多数应用场景还是有参考价值的。

Root本身是一个相对复杂的过程。随着时间的推移，和Android系统的不断更新换代，“攻”与“防”之间的较量也在更替进行，复杂程度也越来越高。在这些Root方法中，很多都是借助于系统自身的漏洞（而且多数属于Linux的漏洞）来完成的。随着漏洞不断被填补，发掘新的漏洞的难度也越来越大了。当然，还有一个方法也值得一试，即“带Root的Rom”包。因为Android系统本身就是开源的，所以要制作一个带Root权限的Rom包并非难事。这也在另一侧面带火了刷机市场，导致市面上各式各样的Rom品种层出不穷。

22.6 APK的加固保护分析

APK加固保护是近几年应用程序开发的一个趋势，它的出现和当前的市场环境有很大关系。

中国互联网协会12321所提供的报告显示，“2015年12月，共有269款App受到了12321举报中心和应用商店的联动下架处置。被下架App数量比11月增加83款，环比增加44.6%。在269款具有危害风险的App中，具有恶意行为的App有195款，具有恶意广告行为的App有71款，具有色情内容的App有14款”，如图22-21所示。

而这些被下架的App中，不乏一些知名软件。它们并非有意制造恶意行为，而是因为没有做好加固保护，给不法之徒提供了“可趁之机”——例如被植入木马，广告等。

从技术实现的角度来看，入侵App的手段有很多。换言之，加固保护方式也需要覆盖这些可能的场景，包括但不限于如下几种：

- 防止二次打包;
- 防止反编译;
- 防止篡改;
- 防止调试;
- 防止窃取;
- 防止注入。

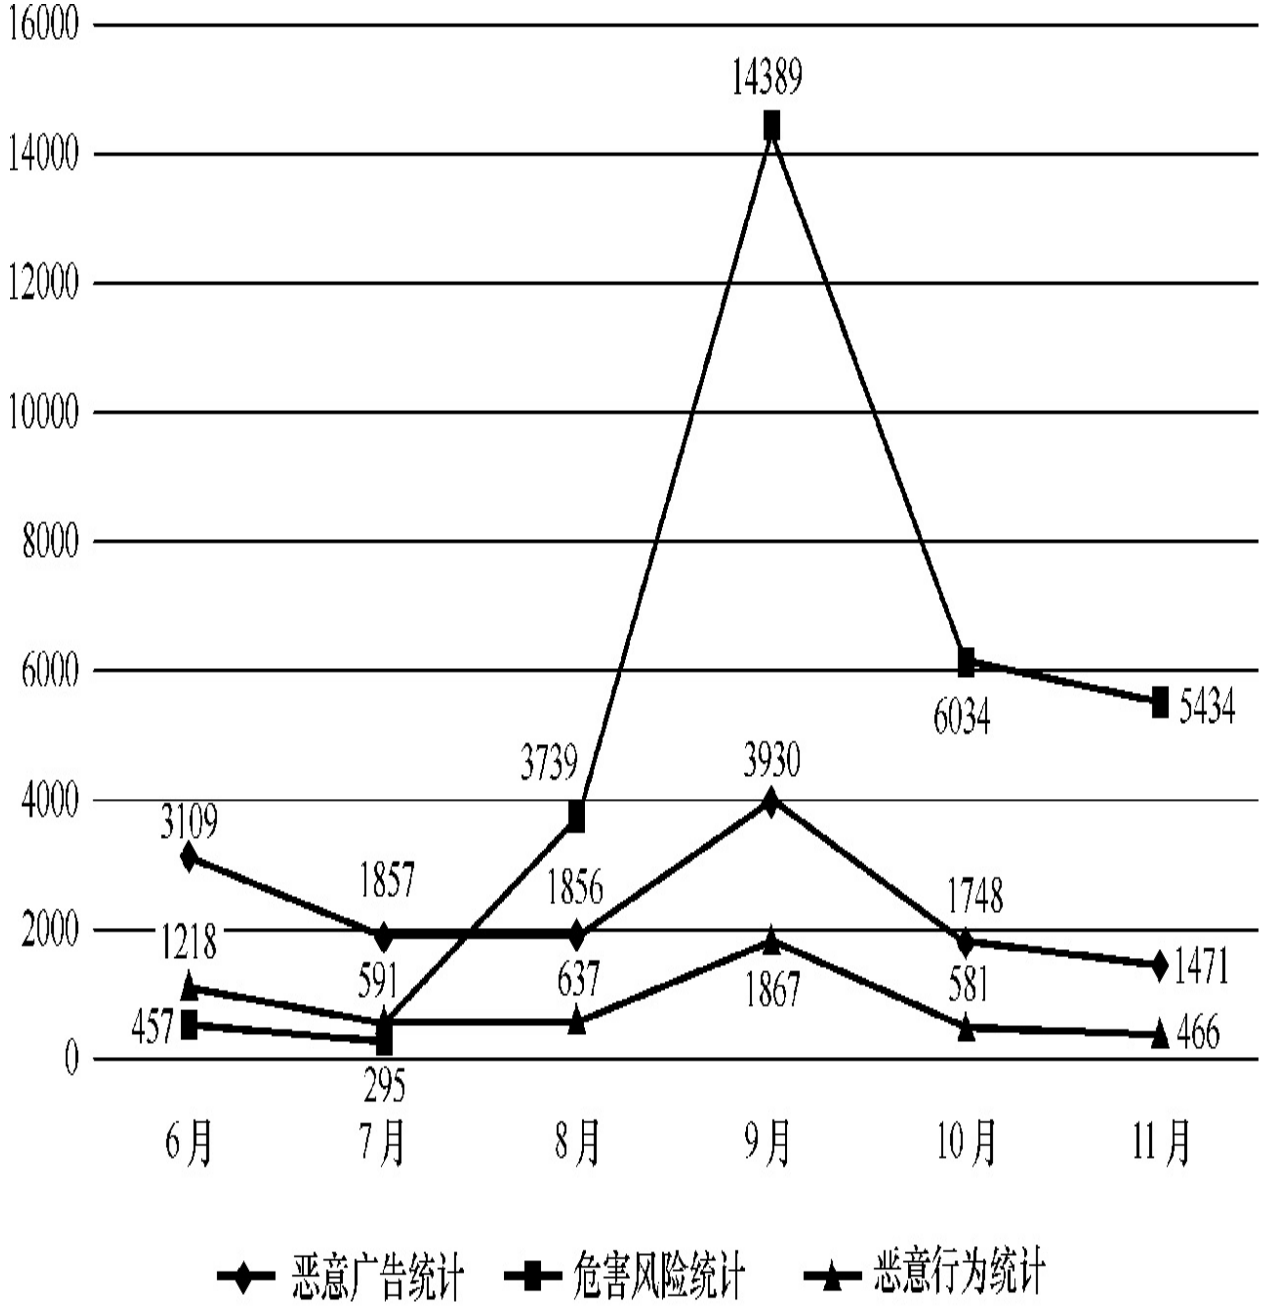

恶意广告统计含：私自获取手机号、私自获取用户位置、私自获取安装软件、私自获取通讯录、私自加载可执行文件、私自启动服务、私自获取 IMEI、私自读取用户账户、私自自启动、私自唤醒手机屏幕

危害风险统计启：低度风险、中度风险、高度风险

恶意行为统计含：恶意扣费、隐私窃取、远程控制、恶意传播、资费消耗、系统破坏、恶意欺诈、流氓行为

▲图22-21　2015下半年App问题统计
（来源于12321）

接下来我们对其中的经典保护手法进行细化讲解。

（1）防止二次打包

如果Android应用程序未采取任何保护措施的话，那么对其进行二次打包还是比较容易的。这主要是由于Android系统对程序的要求只是自签名，而不需要权威机构的认证。因而部分不法之徒完全可以解析原有的APK文件，添加或者篡改其中的内容，然后二次打包来得到一个新的程序文件。那么如何防止程序被二次打包呢？

我们知道，Android系统虽然是自签名，但是在安装时还是会做校验工作——任何无法通过校验的程序都是无法正常使用的（详细信息可以参考本书应用程序打包章节）。因而对于那些被篡改了内容的APK文件来说，如果希望能在Android系统中正常运行的话，就必须经过重签名。换句话说，只要我们可以检测出程序的签名和原始签名是否产生了差异，那么理论上就能侦查出APK被篡改的情况了。

防止二次打包的一个典型处理逻辑是：

Step1. 程序启动；

Step2. 获取当前APK的签名；

Step3. 获取正确的签名；

Step4. 判断二者是否有变化。

虽然步骤并不复杂，但其中的实现细节还需要进一步斟酌。比如在程序的什么地方启动上述逻辑，如何获取到正确的签名，判断签名是否变更的代码段是否也可能被人破解并篡改等。假如验证二次打包的代码本身就存在安全隐患，那么它的输出结果就存在不可确定性了。这些都是我们在为App设计安全保护时需要去深究的。

（2）防止反编译

反编译是利用一定手段，获取到程序可读代码（因为混淆机制的存在，通常情况下是没有办法完全还原出原始代码的）的过程。获取到的程序可读代码，可以被用于分析程序内部的运行逻辑。因而如何守住这一轮攻击，对于保护程序也至关重要。

当前市面上已经有很多成熟的反编译工具，除了收费版本外，还不乏一些主流的开源工具（例如ApkTool和ApkAnalyser都可以从github找到对应的源码工程）。这些反编译工具的功能都是类似的，包括但不限于：反编译、修改、优化、dex转jar、签名、打包等。

防止反编译的一个关键点在于，如何让上述这些工具（或者其他同类衍生产品）或者反编译手法“功败垂成”。

一个最直接的办法，就是对保护对象进行加密。譬如，如果是为了防止APK中的代码被反编译，那么就可以对其中的dex文件执行加密操作。当然，仅仅对dex做加密是不够的，因为我们还需要告诉Android系统如何运行被处理过的dex，即程序在运行过程中的解密操作。

典型的处理步骤如下所示：

Step1. 将原classes.dex做加密操作，并将处理后的结果（假设名称是encrypted.data）转移至APK的其他路径中（如assets或者resource中）。

Step2. 对程序进行加壳处理（也可以将encrypted.data存储到壳程序的dex中）。

Step3. 当程序运行时，首先会执行壳程序（通常是通过JNI和so动态库实现的），后者会根据预先设计的逻辑来加载encrypted.data。

Step4. 壳程序对加载后的data进行解密操作。

Step5. 执行解密后的dex代码。

上述步骤中我们提到了一个重要的概念——壳（Shell）。Shell并非是Android系统首创的，它的诞生由来已久，例如Linux或者Windows操作系统中也经常采用这种技术来防止程序被破解。其基本原理可以参见图22-22。

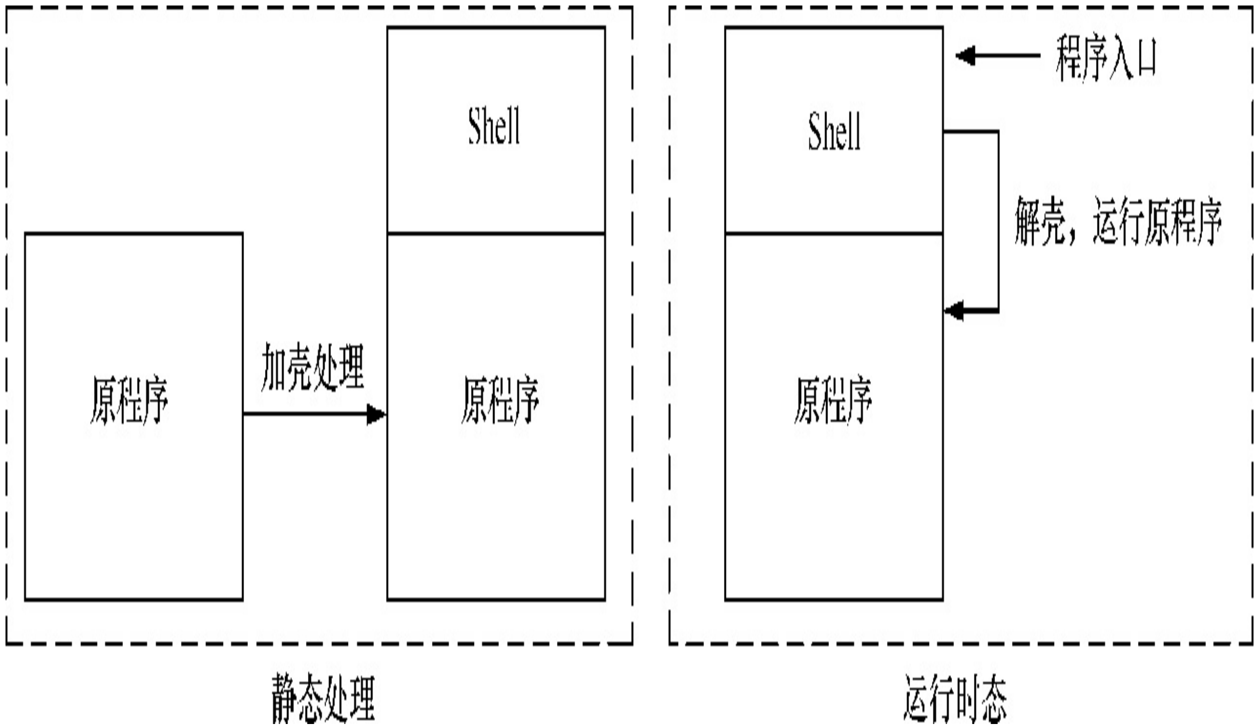

▲图22-22　壳的基本原理

在Android系统中，壳的一个典型应用就是上面所提及的dex加密。其内部原理和图22-22所述的是基本一致的，只不过在细节处理上有些差异。大家可以从“攻”和“防”的角度来再多思考一下，在Android系统中应该如何具体落地加壳措施才是最安全的。

- （3）防止篡改

执行篡改的前提是可以正确反编译出代码，而篡改之后的APK能正常运行于Android系统中的条件则是二次打包，所以理论上来讲做到我们前面分析过的两点就可以有效阻止篡改事件发生了。

- （4）防止动态分析调试

那么有没有可能在不改变APK的情况下，来完成一些“非常规”的操作呢？答案是肯定的，比如利用调试手段来获取APK的某些关键内部信息。

在Android系统中，能否调试应用程序是需要同时满足多个条件（譬如AndroidManifest.xml中需要指明

android:debuggable=“true”）的，因而我们可以从这些条件入手防止APK被调试。

另外，除了预置这些条件外，我们还需要阻止第三方人员非法篡改它们。一个简单的做法是在代码中做二次检查，确保这些条件符合我们最初的设置。

- （5）防止模拟器运行

在某些情况下，模拟器可以为非法分析APK提供便利条件，例如：

- 模拟器可以很方便地获得root权限；
- 模拟器对应用程序调试条件的限定相对宽松。

所以对于将要发布的应用程序，我们可以通过一些必要的手段来阻止它们(或者增加难度)被安装和运行于模拟器中。模拟器和真机从多个方面都存在差异，包括但不限于：

- 模拟器中的IMEI号并不是真实的硬件设备号；
- 模拟器中的dev目录下有某些特殊的文件，例如/dev/socket/qemud;
- 模拟器中的build信息和真机存在差异；

例如模拟器的BRAND可能为“generic”，HARDWARE可能为“goldfish”；

……

虽然以上这些信息经过努力都是可以被伪造出来，但不法分子多少都需要付出一些额外的代价。所以在一定程度上可以提高破解的难度，为应用程序增添更多的安全性。

本小节的最后，我们再来对加固技术做个小结。现有的加固技术虽然很多，但它们大多具备如下几个特点。

- 这些技术的实现都是在应用程序进程中完成的，换句话说它们的能力在一定程度上会受限于Android系统。模型如图22-23所示。

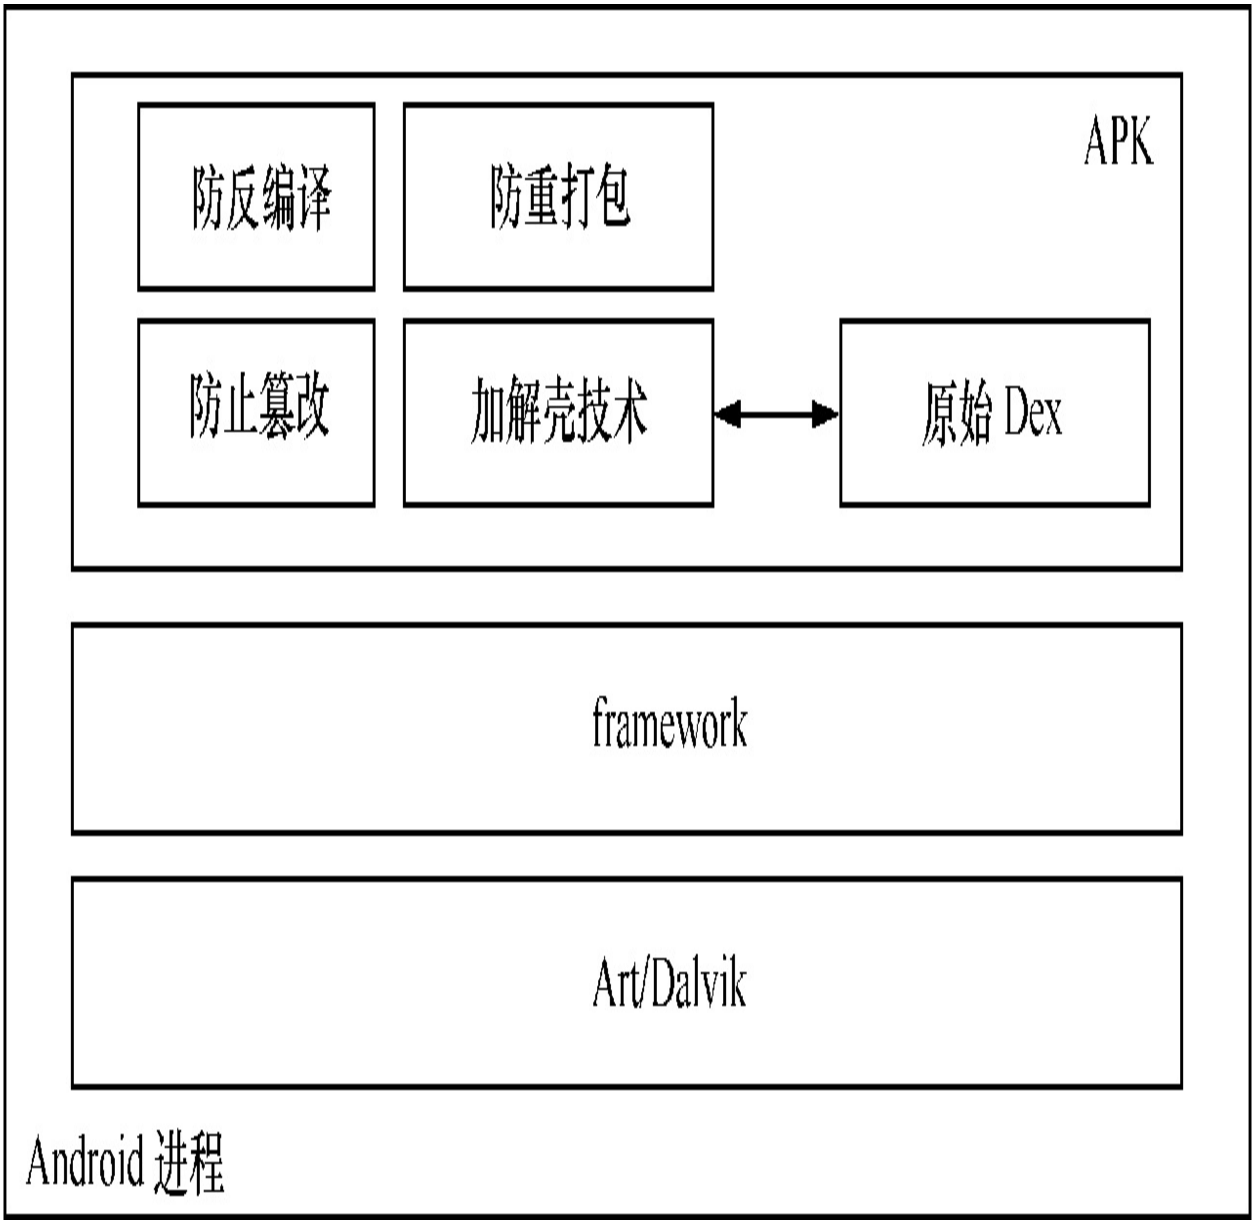

▲图22-23　Android加固技术实现模型简图

- 多数加固技术会运用到反射等技术来完成一些系统禁止的“非法”操作

这样一来随着Android系统策略的收紧，它们的处境也会越来越困难。譬如从AndroidN版本开始，Android系统就不允许应用程序使用非标准NDK的接口;对于反射调用系统接口的做法也予以控制。这些问题都是加固技术所需要去重点考虑的。

- 所有加固技术都必须遵循标准的Android应用程序生命周期
- 在系统调用加固程序所提供的代码之前，它们必须处于就绪状态
- 例如加壳技术会对dex或者部分函数进行加密保护，那么就必须保证系统在访问特定函数之前，后者已经被解密并且处于正确的状态，这样一来应用程序才能正常地运行。

“攻”和“防”是一个相生相克的过程，相信随着Android系统的不断发展，市面上会出现更多的加固和解固技术，敬请期待。

第4篇

Android系统工具

Android系统这个“大杂烩”不仅融合了众多知名的开源大项目，同时也有各式各样的小工具。这也是开源工程的一大好处，可以最大限度地使用已有资源，从而防止重复开发。而且通过合理的组织，各个工程项目又有自己独立的发展方向，形成“百花齐放”的局面。

一方面，这些工具是Android系统不可或缺的一部分，如adb，adt，logcat等。无论是系统移植、驱动开发人员，还是上层应用程序的开发者，相信都不可避免地要借助它们来完成项目的研发工作。另一方面，我们在实际项目经验中发现，不少工程人员对这些工具“只知其一，不知其二”。换句话说，只对他们常用的一些功能熟悉，而当项目提出新的需求时就束手无策了。

这主要是因为不少人没有系统地研究过这些工具的实现原理，所以还未形成完整的“知识体系”。本篇内容将同时从理论和实践两个角度来思考这些项目研发中的常用工具，希望读者在学习后对它们能有更彻底的认识。

第23章 IDE和Gradle

第24章 软件版本管理

第25章 系统调试辅助工具

第23章 IDE和Gradle

Android Studio除了让越来越多的开发者了解到IntelliJ这个优秀IDE平台的存在外，还同时“带红”了另一个工具，这就是“Gradle”。

相信大家对这个新一代的自动化编译工具并不陌生，因为Android Studio上的应用程序开发默认情况下就采用了Gradle做为自动化构建工具，如图23-1所示。

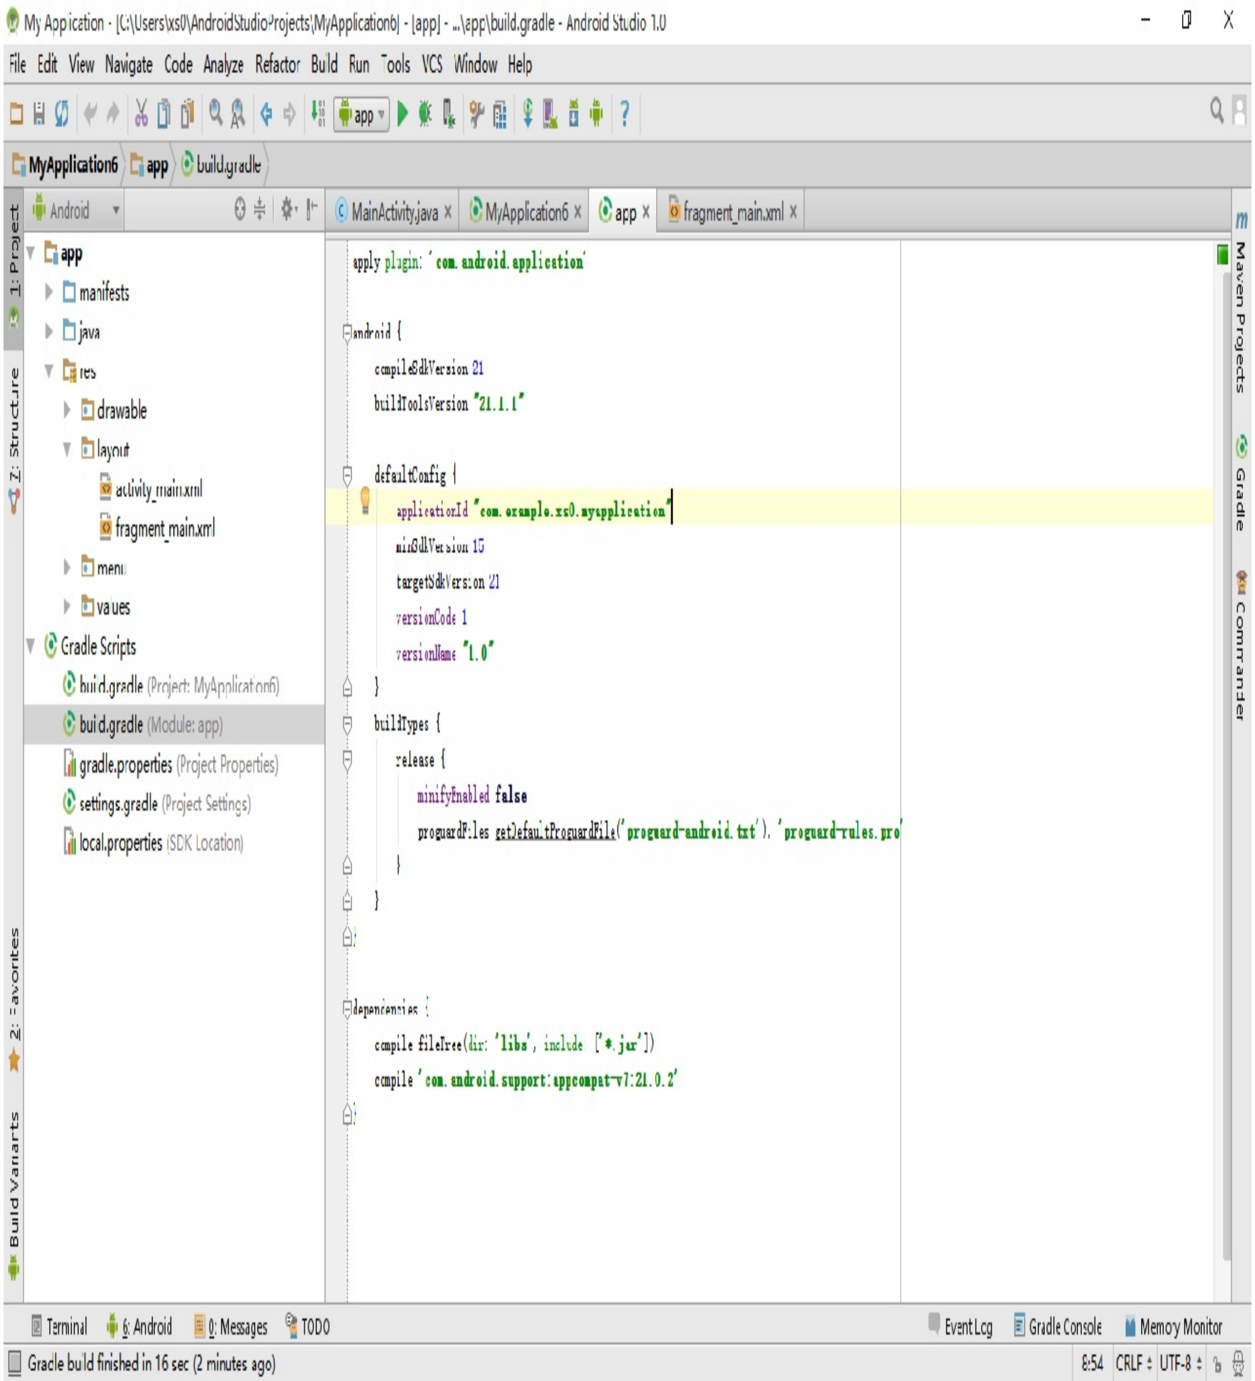

▲图23-1　Gradle是Android Studio默认的自动化工具

那么Gradle为什么可以得到Google如此的青睐，它和以前的Ant、Maven自动化构建工具相比有什么区分呢？对于普通开发人员来说，如何迅速掌握Gradle的核心要点，并融入到这一新家庭中来呢？

这些都是我们在本章节中所要回答的问题。

23.1 Gradle的核心要点

科技的发展历史折射出一个潜在的规律，即一个新技术的出现总是伴随着行业棘手问题的解决而来。也只有在这种背景下产生出来的新技术，才能在“适者生存”的环境中获得更好的发展。

对于不少开发人员来说，新技术的出现对他们则是“有利有弊”的。“利”的方面就是可以帮助他们更快地解决工作中的难点，摆脱旧技术瓶颈带来的噩梦般的“修修补补”；“弊”也是明显的，比如他们需要对现有工作做升级改造，需要学习一门新的技术甚至语言等，这些都意味着精力和时间成本的投入。

换句话说，如果一门新技术可以满足以下两点条件，那么无疑将获得更多人的喜爱。

- 条件1：较为全面地兼容开发者的现有工作。
- 条件2：学习曲线相对平缓。

Gradle是在Ant、Maven等自动化编译工具“前辈”们的基础上发展起来的。从它的官方宣传中可以看到，Gradle从一开始就吸收了以上这些工具的优势，并通过开创性的技术来弥补它们中的不足。从这个角度上来讲，Gradle是满足条件1的。不过，由于Gradle的很多知识点对于开发者人员而言是从未接触过的（譬如Groovy语言和DSL，更多的人可能是“只闻其名，未见其身”），所以初学者如果想迅速掌握Gradle并非易事，甚至有些分析人员将Gradle的学习曲线定义为“非常陡峭”；也有部分开发人员在Gradle官方论坛表达了他们在学习Gradle过程中的烦恼，比如下面这位：

“Being a newbie, I often struggle with creating the wiring necessary for writing and automated testing custom plugins. It's a big leap for a not-so-smart guy like me to go from Java/Ant/Ivy to Groovy/DSL/Gradle.

…

Let me throw out another idea that might be unpopular: Provide more APIs and examples in pure Java. I think you might

find more adopters if the learning curve didn't appear to be so steep. Sometimes, Groovy is the only way you can do some things. However, I constantly find myself being tripped up having to learn Groovy at the same time as Gradle. If I could just learn one thing at a time, that would have been better. It'd be great if the adoption curve had a roadmap with examples & APIs that were initially Java based with a few necessary Groovy closures and let people discover the more elegant solutions later on.”

上面这段话反映出了不少初学者的“烦恼”——对于Groovy等新语言的不熟悉，阻碍了他们学习Gradle的步伐。再加上Gradle在超越前辈们的同时，也需要更多创新点。对此，《Building and Testing Gradle》有过精确的描述，如下所示：

“Gradle is occasionally described as a Groovy-based Ant. That would be the role that

Gant fills, but Gradle has much more ambitious aims. Gradle offers the flexibility of

Ant, which many teams still cherish, but with the dependency management style of

Ivy, the intelligent defaults of Maven, the speed and hashing of Git, and the metaprogramming power of Groovy. That potent best-of-breed blend is an intrinsic motivator for joining the Gradle movement.”

但是对于开发者，特别是普通应用程序开发人员而言，并不是所有这些优秀的特性对他们都是必需的。如何避免少走弯路，把精力放到我们需要用到的知识点的学习上，既是Gradle初学者共同的诉求，同时也是接下来我们想要帮助大家达成的目标。

23.1.1 Groovy与Gradle

如果把Gradle构筑的编译工程比作“大厦”的话，那么毫不夸张地说，Groovy是这栋大厦的“地基”。Gradle正是站在巨人的肩膀上，充

分利用了Groovy语言本身的优秀特性才能获取如此迅速地发展。

我们不希望在本书中大谈特谈Groovy的各种语法，因为大家完全可以查阅专门的资料来获取这些信息。本小节的重点是为大家剖析Groovy中与Gradle相关的重要特性，以帮助大家迅速理解Gradle的使用和内部基本原理。

在学习Gradle的过程中，我们一定要记住下面这句话，这有利于大家在游走于Gradle所构筑的摩天大楼中不至于迷失方向：

Gradle脚本是基于Groovy语言的，因而它一定需要遵循Groovy的语法

Groovy和Java语法很类似，从这个角度来说可以在一定程度上降低开发人员学习新语言的难度。同时，Groovy和Java可以达到二进制级别的兼容——换句话说，对JVM而言它们两者没有任何区别。Groovy还可以使用Java中的各类API，两者可以进行混合编程。这些都是Groovy这个动态语言与生俱来的优势。

（1）与Gradle相关的Groovy核心特性1：闭包（Closure）

先来让读者有一个感性的认识，下述代码段就使用到了闭包：

```
def greeting = { "Hello, $it!" }
assert greeting('Patrick') == 'Hello, Patrick!'
```

第一行语句中，我们定义了一个闭包greeting;然后在第二个语句中，通过向闭包传入“Patrick”来使用它，并判断输出结果是否符合预期。大家应该会觉得这和函数调用有点类似，只不过更为新颖，而且控制更加灵活。

官方对Closure的定义如下：

A closure in Groovy is an open, anonymous, block of code that can take arguments, return a value and be assigned to a variable.

它的基础语法规则如下：

```
{ [closureParameters -> ] statements }
```

顾名思义，closure需要一对“{}”来将所要表述的代码块(block of code）“框”起来，并作为一个整体对象来处理。[closureParameters ->]则用于表示这个闭包中所需的各种参数，类似于Java/C等语言中的函数参数。“[]”表示这一字段是可选的，譬如我们在上面举的例子中就没有带任何参数声明。不过这并不代表这种情况下Closure是没有参数的，只是Groovy会自动帮我们判断和分析，从而省去了人工书写的繁琐过程。紧随参数的是真正的代码实现部分，即“statements”，对应我们例子中的“Hello, $it!”。

为了加深大家的理解，我们再从Groovy官方文档中摘录部分合法的Closure样式来供大家参考，如下所示：

```
{ -> item++ }                                         样式1

{ println it }                                        样式2

{ it -> println it }                                  样式3

{ name -> println name }                              样式4

{ String x, int y ->
    println "hey ${x} the value is ${y}"              样式5
}

{ reader ->
    def line = reader.readLine()                      样式6
    line.trim()
}

{ item++ }                                            样式7
```

样式1：A closure referencing a variable named item。

样式1：通过“->”来显式分隔开闭包参数和代码实现。

样式2：使用隐含的参数“it”。

样式3：实现和上一样式同样的功能，只不过这一次参数是显式的。

样式4：在某些情况下最好使用显式的参数。

样式5：在闭包中使用两个参数。

样式6：闭包中可以包含多条代码语句。

样式7：完全不使用参数的情况。

如果需要了解闭包的更多详细资料，建议大家可以参考官方的文档说明。

（2）与Gradle相关的Groovy核心特性2：Command Chains

Groovy可以让开发者完成不需要圆括号(parentheses)的函数调用。举个例子来说，有如下一个函数：

```
void turn(String direction)
{
    //Do sth
}
```

在Java语法下，我们想表达“向左转”时用的是turn(“left”)；而Groovy下则可以让函数调用看上去更为自然：

```
turn left
```

（注：个人认为这种“自然”是相对而言的，对于习惯于严格的语法规则的开发人员来说，这种“随性”的方式反而有可能让他们“无所适从”。因而凡事都有两面性，应该一分为二地看待问题）。

不仅如此，Groovy还可以在上述的基础上让多次的连续函数调用间不需要书写“.”。也就是说当向左转了以后还需要向右转，那么Groovy中的表达就是：

```
turn left then right
```

这句话对应的函数调用则是：turn(“left”).then(“right”)。

这就是Groovy的Command Chains想要达到的效果。

当然，这种表达方式如果遇到没有函数参数的情况就要特别注意了，比如：

```
select(all).unique().from(names)
```

显然如果还按照之前的方式来表达就会引起混乱，因而我们需要这样来调用：

```
select all unique() from names
```

因为风格不统一，这个语句多少看起来有点奇怪。所以在使用Groovy的这一特性时，建议大家多想一下有没有可能出现类似的现象，不然很可能是“得不偿失”的。

（3）与Gradle相关的Groovy核心特性3：运算符重载

Groovy中的不少运算符会被映射为针对对象的常规函数调用。譬如：

```
a+b    会被Groovy解释为  a.plus(b)
a-b     会被Groovy解释为  a.minus(b)
a[b]=c    会被Groovy解释为  a.putAt(b,c)
```

开发者可以灵活利用这个特性来达到一些特殊的效果。比如Gradle脚本中添加一个task可以采用如下的语句：

```
task helloWorld << {
    println 'hello, world'
}
```

也可以通过如下语句来为同一个task添加多个action：

```
task multiAction
multiAction << {
   println 'This is '
}
multiAction <<{
   println 'multiAction'
}
```

那么当我们执行“gradle multiAction”时，会打印出“This is multiAction”。

（4）与Gradle相关的Groovy核心特性4： 动态类型

Gradle和不少脚本语言一样，可以不需要显式地声明变量类型，而由系统在运行时动态地识别出变量的类型。如下代码范例所示：

```
private TestFile hashFile(TestFile file, String algorithm, in
    def hashFile = getHashFile(file, algorithm)
    def hash = getHash(file, algorithm)
    hashFile.text = String.format("%0${len}x", hash)
    return hashFile
}
```

可以看到，变量hashFile和hash都没有特别指明它们所属的类型，这样并不会导致任何问题（当然，主动声明也是可以的，比如变量len和algorithm）。另外，各个语句间不需要像C++/C和Java那样以分号“;”相隔，这种做法普遍存在于各类脚本语言中。

23.1.2 Gradle的生命周期

和其他自动化编译工具一样，Gradle也有其生命周期，具体而言包括Initialization、Configuration和Execution三个阶段，如图23-2所示。

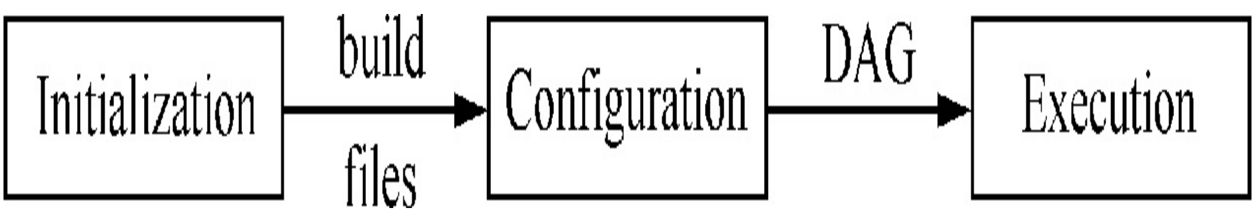

▲图23-2 Gradle的生命周期

- Initialization

在初始化阶段，Gradle的主要职责是定位有哪些需要处理的build文件。当Gradle启动后，它会分析开发者是希望编译单个工程还是多个工程。如果是前者的话，它会识别出一个单独的build文件并作为下一阶段的输入；而如果是多个工程的情况，它需要找出潜在的多个build文件并让它们成为下一阶段重要的编译依据。

- Configuration

在配置阶段，Gradle会根据上一阶段的结果主动处理单个或多个build文件。可想而知这些文件对它而言都是Groovy脚本，相当于是Gradle解释执行了一个由build源代码组成的编译“小工程”。

不过需要特别注意的是，此时并不意味着Gradle已经开始进行真正的工程编译了，它在这一阶段的目标产物实际上是一个由task所组成的DAG图（Directed Acyclic Graph）。这一点和我们在本书Android系统编译章节所讲的Make自动化工具非常相似，因为只有先决定出Target的依赖关系，才能够保证其正确地获取最终的目标产物。

另外，这一阶段会主动回调开发者编写的各种hook方法（如果有的话）。

- Execution

这是真正体现Gradle价值的一个阶段，它会基于上一步中的DAG结果来生成目标产物。毋庸置疑，Gradle对各个task的执行顺序是严格按照它们的依赖关系的。所有的build活动（包括编译源码、拷贝文件等）在task中定义的action都将在这一阶段得到执行。

开发者同样可以为这一阶段设置各种hook方法，以按照自己的需求来改变Gradle的编译行为。

经过这3个阶段，Gradle才能完成它的自动化编译使命。由此可以推断，Gradle本身的编译过程不会很快，在某些情况下(比如依赖于网络包)甚至会出现让用户感觉“缓慢”的现象。当然，鉴于Gradle所提供的非常灵活的实现方式，这些代价都还在可接受的范围。

23.2　Gradle的Console语法

Android Studio对采用Gradle进行编译的方式进行了封装，让开发者只需单击几个按钮就可以完成工作了。因而如果开发者不需要对build脚本做任何修改，那么我们并不一定要掌握Gradle的Console语法;反之如果我们希望了解build脚本的运行过程，并根据自己的需求来编辑build文件，那么Gradle的命令行控制方式是大家必须要熟悉的。

从Gradle官网上下载的发行版本目录结构如图23-3所示。

其中bin目录下保存的就是Gradle的可运行文件，如图23-4所示。

名称	类型	大小
bin	文件夹	
init.d	文件夹	
lib	文件夹	
media	文件夹	
changelog.txt	文本文档	1 KB
getting-started.html	HTML 文件	855 KB
LICENSE	文件	51 KB
NOTICE	文件	1 KB

▲图23-3　目录结构

名称	类型	大小
gradle	文件	5 KB
gradle.bat	Windows 批处理...	3 KB

▲图23-4　可运行文件

Windows系统下对应的是批处理文件“gradle.bat”。Gradle是基于Groovy语言的，换句话说它的运行环境依赖于JVM，所以这个bat文件的主要任务就是初始化虚拟机，并通过以下语句来启动和运行Gradle的核心程序：

```
"%JAVA_EXE%" %DEFAULT_JVM_OPTS% %JAVA_OPTS% %GRADLE_OPTS% "-Dorg.
```

Gradle的命令行语法如下所示：

```
gradle [option...] [task...]
```

目前支持的option如表23-1所示。

表23-1　Gradle的主要option释义

Option	Description
-?, -h, --help	打印帮助信息
-c, --settings-file	指定Gradle的settings文件
-b, --build-file	指定Gradle的build文件
-g, --gradle-user-home	指定Gradle的user home目录
-d, --debug	打开调试模式
--	使用Gradle daemon来编译工程。Daemon是一个守护进程，优点是可以在非首次编译时加快速度，缺点则是

daemon	可能会因为持续运行而引发的不可预期的编译问题。这和Jack Server的原理是基本一致的。开发者可以根据自己的需求做折衷选择
--gui	打开Gradle的GUI操作界面，参见后面的截图
--parallel	多线程并行编译工程。Gradle会计算出最合适的线程数量
-x, --exclude-task	需要在编译时被排除的task

更多命令行选项，大家可以通过使用“gradle --help”来获取和学习。

Gradle也提供了GUI形式的控制方式，主界面如图23-5所示。

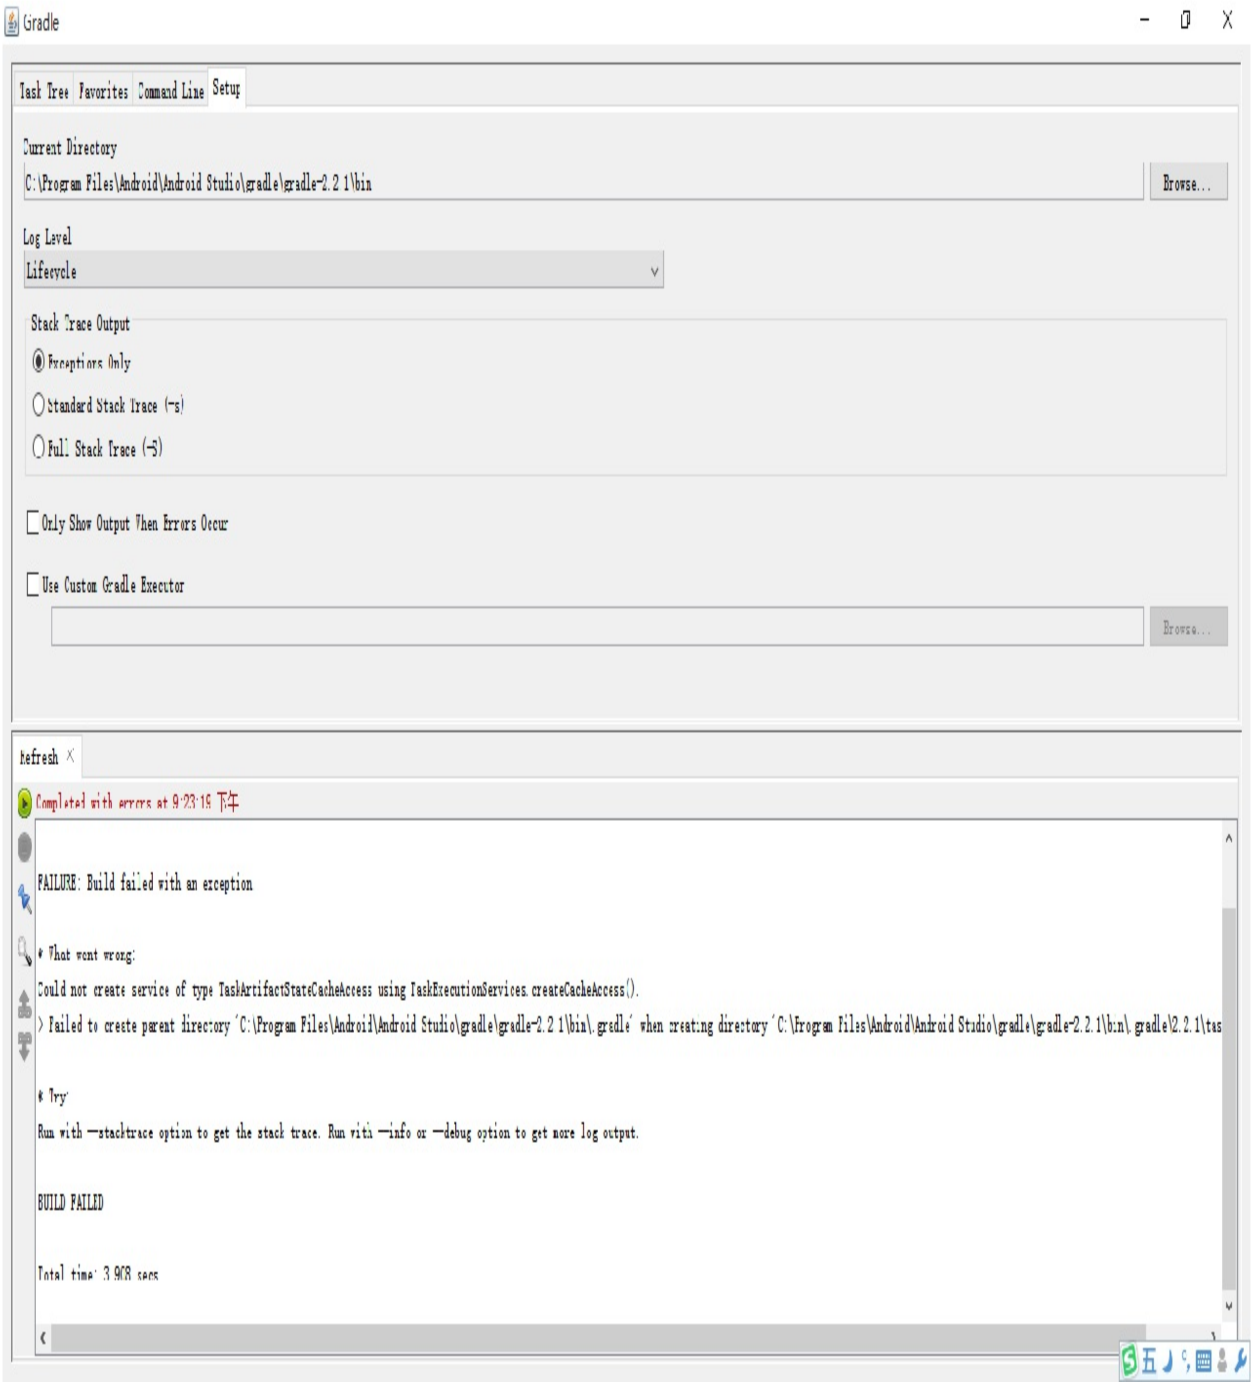

▲图23-5 Gradle的GUI主界面

不过Gradle所提供的上述GUI还不能满足Android Studio IDE的需求。所以它自己对Gradle进行了一定的UI封装，如图23-6右边部分所示的“Gradle tasks”。

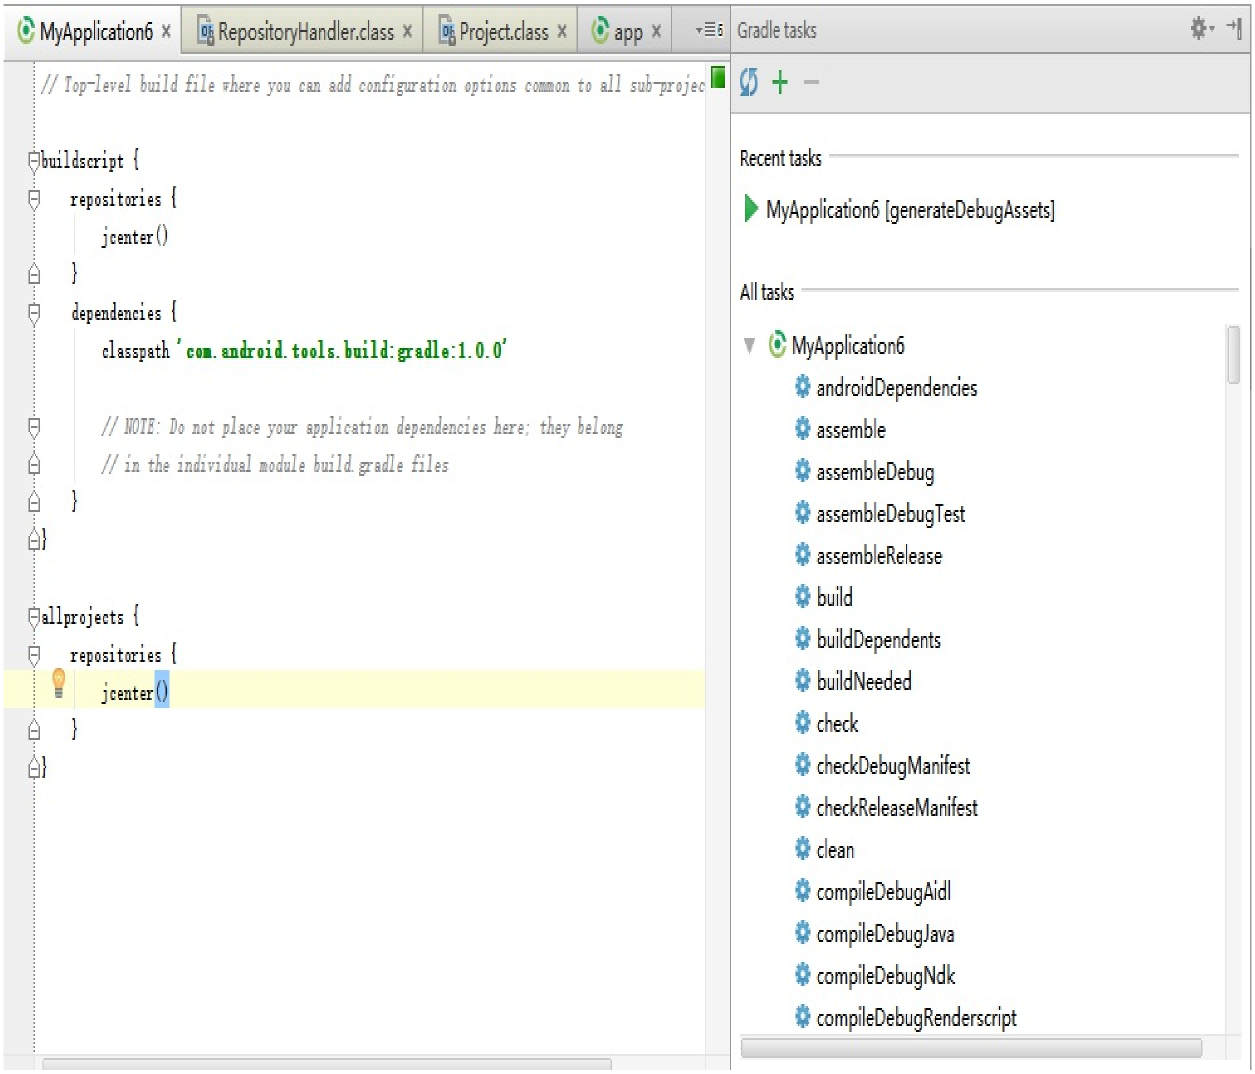

▲图23-6　Android Studio对Gradle的封装

Gradle提供了查询工程项目中所有可用任务的命令，即“gradle task”。一旦用户使用了这个命令，Gradle会通过解析build脚本来分析针对这个工程项目的所有tasks。上述的“Gradle tasks”实际上就是针对这一命令的图形化。我们可以通过一个小实验来做一下验证，就是给build脚本的最后面手工添加一个task，如下所示：

```
task aNewTask{
     println “This a new task”
}
```

然后单击Gradle tasks中的 来刷新列表，更新后的结果如图23-7所示。

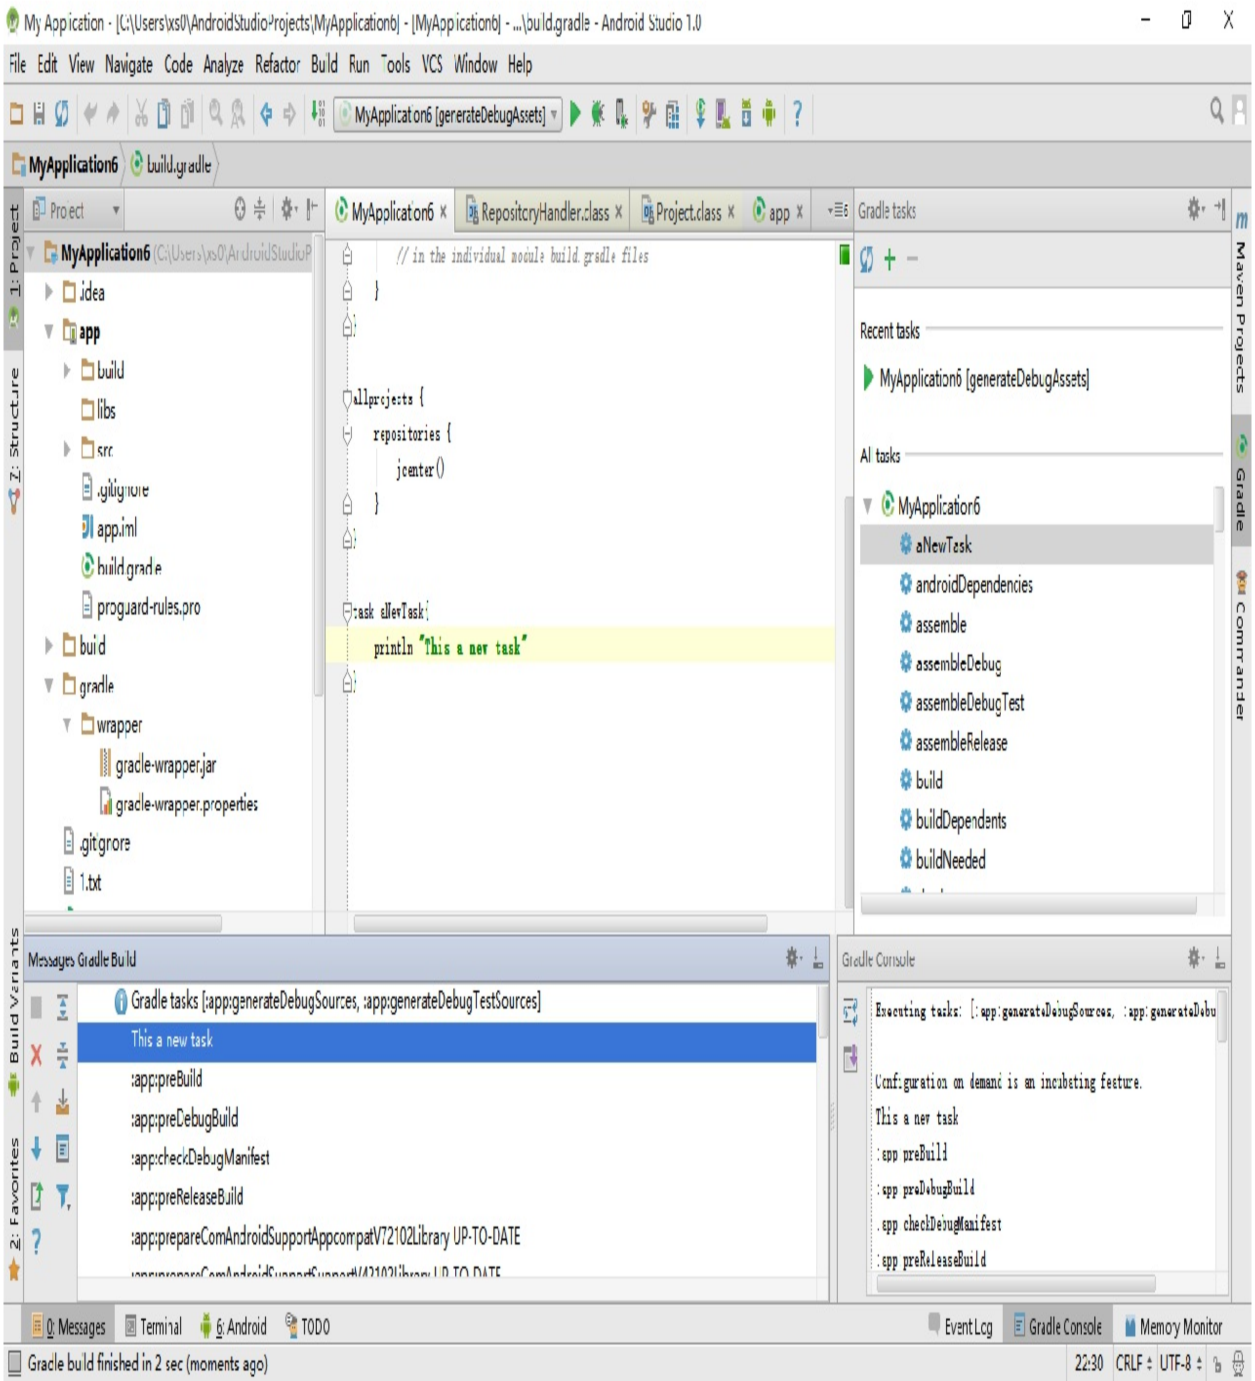

▲图23-7　更新后的结果

可以看到左下角的Message框中打印出了我们这个新Task中定义的Action，即“This is a new task”，同时右边部分的“All tasks”也列出了新增的这个任务。我们从这个小实验还可以得出另一个结论：Gradle在Configuration阶段会首先处理Project Level的脚本，然后才

是各个子项目。

23.3 Gradle Wrapper和Cache

Android开发人员对于Gradle Wrapper应该不会陌生，因为不论是IntelliJ还是Android Studio，都提供了Wrapper相关的配置项，如图23-8所示。

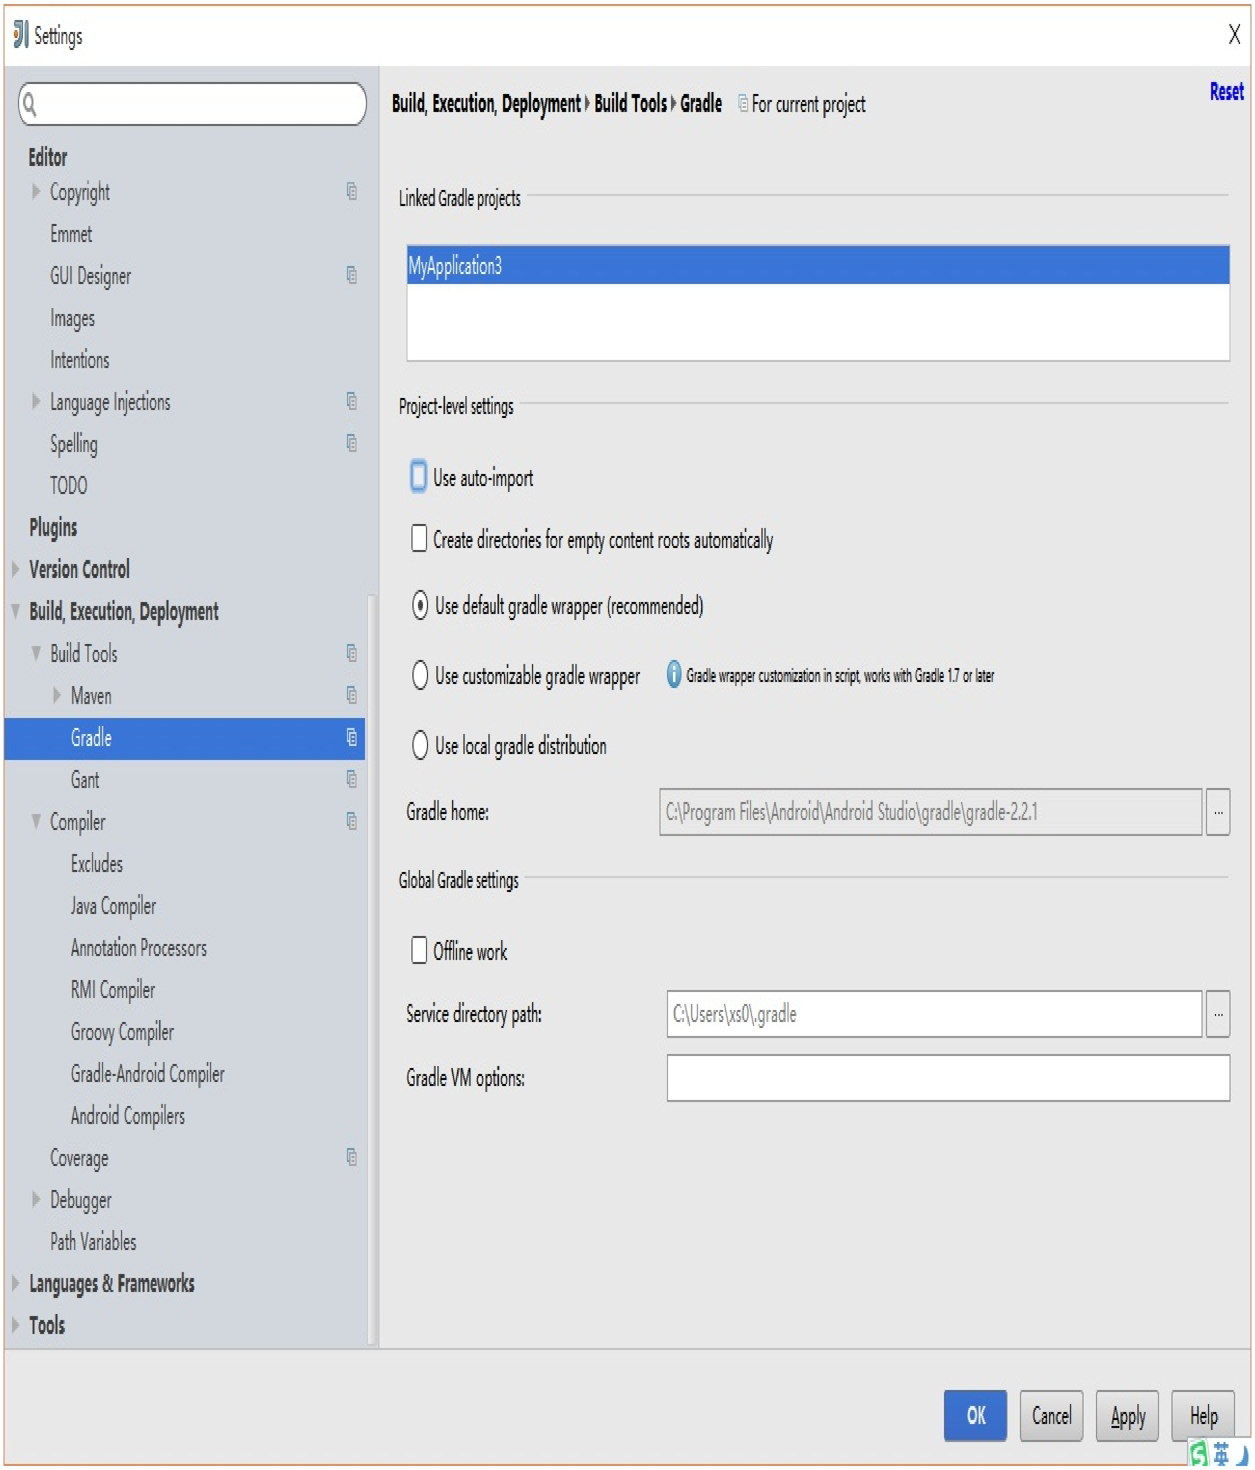

▲图23-8　配置项

图23-8中提供了3个单选项。

- Use default gradle wrapper

这是推荐的方式，使用wrapper形式的Ggradle。

- Use customizable gradle wrapper

  使用定制的Gradle Wrapper。

- Use local gradle distribution

  使用本地的Gradle版本。

从上述几个选项中大家应该能大概猜测到，Wrapper是一种类似于“包装纸”的东西——我们只能看到外面的“接口”，而里面的具体实现方式则由Wrapper来决定。这样的话我们就可以不要求开发机器上一定要预先安装Gradle了，Wrapper会根据需要自动连接网络，并下载Gradle版本来完成编译工作。

当我们新创建一个利用Gradle来构建的Android工程（注：这里需要特别说明的是，Android工程并非只能通过Gradle来构建。譬如早期的Android应用程序开发大部分是在Eclipse中完成的，而默认的构建工具是Ant。随着Android Studio指定Gradle为默认的构建方式以后，越来越多的开发者采用它来代替之前的构建工具）时，IDE会自动为我们生成一个Gradle目录，其中就包含了Wrapper实现，如图23-9所示。

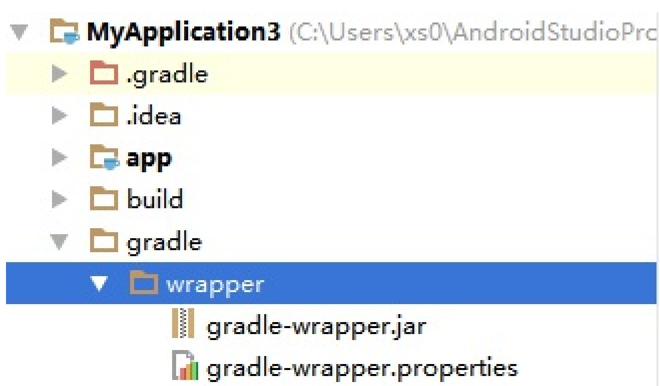

▲图23-9　Gradle目录

如果我们手工删除掉这个Gradle文件夹，那么IDE中的Gradle配置选项就会发生变化，如图23-10所示。

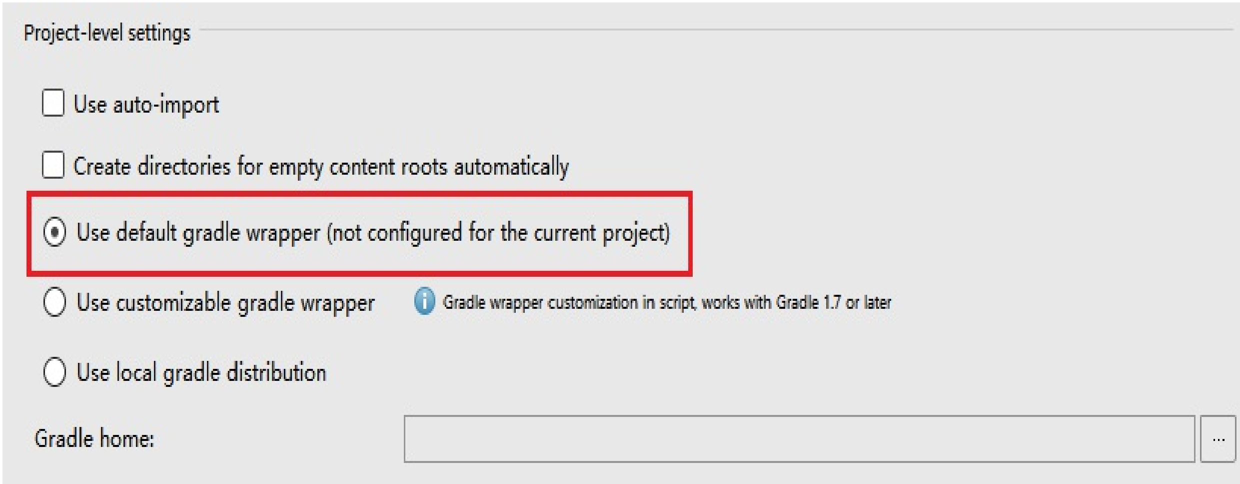

▲图23-10　配置选项的变化

因为无法找到可用的Wrapper，IDE会自动将之前的“recommended”更换为“not configured for the current project”。

通过上面的描述，我们知道Wrapper应该随工程文件一起被check in到version control库中。这样做的另一个好处是，用户总可以使用到与工程最匹配的Gradle版本来完成编译，同时也意味着持续集成服务器上不需要预先安装和配置Gradle了。

那么Wrapper是如何做到这些的呢？

事实上，除了前面所述的Wrapper文件外，新建的Android工程根目录下还有几个重要的可执行文件，如下所示：

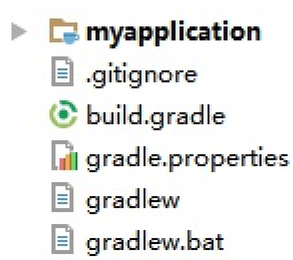

其中gradlew.bat针对的是Windows平台，而gradlew则适用于其他操作系统平台。这和前一小节中所见的Gradle命令行程序可以说是“如出一辙”。我们只要保证Gradle和gradlew在“包装纸”上保持一致，

那么对调用者来说就可以做到“透明”了。

理解了Gradle Wrapper的实现原理后，我们最后再简单分析一下gradle cache。可想而知，Gradle程序本身，及Gradle脚本中描述的工程中的各种依赖关系库在构建阶段都需要在本地存在。换句话说，如果发现这其中有任何文件缺失的话，Gradle有责任通过开发者声明的jcenter、maven仓库去获取并下载。为了避免多次地重复下载，Gradle会在本地建立一个cache来保存这些文件。

Gradle同样提供了选项来帮助开发人员管理cache，大部分IDE则提供了更为便捷的GUI界面，如图23-11所示是IntelliJ中的截图。

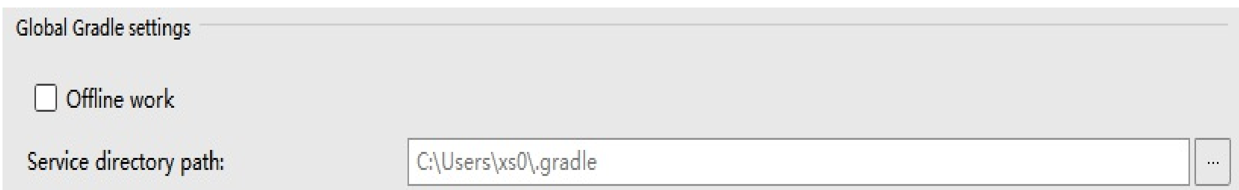

▲图23-11　IntelliJ截图

“Offline work”会告诉Gradle不要尝试连接和使用网络功能。这会出现两种情况，假设本工程所需的所有依赖文件和内容在本地都可以找到，那么Gradle仍然可以顺利地完成编译工作；否则它会报错，并提示开发者有哪些无法找到的文件。

“Service directory path”就是Gradle保存缓存文件的地方，在Windows操作系统下通常对应的是用户目录。大家可以做一个实验来证实我们的猜测：准备两台PC，其中一台可以正常连接网络，此时新创建的Android工程应该可以成功编译通过；另一台机器无法使用网络，并只预先安装了Gradle的发行版本，此时新创建的Android工程应该会有依赖文件无法找到（譬如id值为'com.android.tools.build:gradle:1.0.0'的Gradle插件）。此时如果我们把第一台机器的“Service directory path”文件夹中的内容复制到第二台机器的相应位置，那么后者也同样可以正常构建和运行了。

关于cache还有很多技术细节，有兴趣的读者可以自行研究Gradle的源码来了解详情。

23.4 Android Studio和Gradle

23.4.1 Gradle插件基础知识

Gradle支持通过插件的方式来扩展功能，以保证开发者可以按照自己的需求来完成自动化构建。而且Gradle插件允许以任何语言编写——当然前提是插件代码最终可以被编译成字节码。实际上JVM的宗旨是成为一个通用的规范标准，因而它并没有强制限定开发人员必须通过Java语言来编写能在虚拟机上运行的程序。Groovy、Scala、Clojure这些语言都充分利用了JVM的这一特点，既在巨人的肩膀上实现了自身语言的独特优势，同时也保证了与其他JVM程序的兼容性，可谓一举多得。

除了语言的选择外，Gradle还提供了如下几种插件编写方式“任君选择”：

- Build Script

你可以在build脚本中直接完成插件代码的编写。这种方式的缺点是，代码只能在一个脚本中使用，优点是开发编译都很方便，而且Gradle会自动将其加到classpath（注意，这个classpath不是指应用程序工程中的classpath）中。因而适合于插件代码不多，且不需要与其他工程共用的情况。

- buildsrc工程

除了应用程序工程，Gradle脚本同样也可以作为工程进行管理。默认情况下，Gradle会自动处理如下路径下的插件源码，并将其添加到classpath中：

```
[Project_root]/buildSrc/src/main/groovy
```

这种方式的可见范围相比上一种要大一些，即这个应用程序工程的所有build脚本中都可以使用，但也仅限于本应用程序范畴。

- Standalone project

以独立工程的形式来实现Gradle插件是不少开发者的选择，特别是

那些应用范围广泛的插件，如android plugin。在这种情况下，插件以JAR包存在，并支持在一个包中包含多个插件。

接下来我们将以一个简单的范例来让大家对上述第一种方式实现的插件有一个直观的认识;下一个小节中的android gradle plugin则是Android Studio工程提供的以Standalone方式存在的Gradle插件：android plugin。对于第二种方式感兴趣的读者可以自行查阅官网资料。

按照Gradle的规定，用户自定义的Gradle插件需要实现Plugin接口。当我们在build脚本中使用插件时，则可以通过apply plugin:[PLUG_IN]来指明。然后Gradle会调用该插件中的apply函数，实例如下：

```
apply plugin: GreetingPlugin

class GreetingPlugin implements Plugin<Project> {
    void apply(Project project) {
        project.task('hello') << {
            println "Hello from the GreetingPlugin"
        }
    }
}
```

上述插件范例用于添加一个名为“hello”的task。值得一提的是，Gradle会通过函数参数传入一个重要的对象，即工程对应的Project实例——这个变量可以说是插件参与到工程中的“桥梁”，例如GreetingPlugin就使用到了project.task。

这个范例虽然简单，但“麻雀虽小，五脏俱全”，其他复杂的Gradle Plugin就是在这些基础上构建起来的。

23.4.2 Android Studio中的Gradle编译脚本

本小节我们以Android Studio中的编译脚本为基础，结合Gradle内部的实现原理来帮助大家理解Android Studio中应用程序的编译过程，以及Gradle所支持的Standalone方式的插件。图23-12即是通过Android Studio新建一个工程后由IDE产生的build脚本。

值得一提的是，这个例子很好地解释了Gradle的Multi-project结

构。从图23-12中可以看到，Android Studio自动生成了两个Gradle脚本，一个是面向整个Project的，另一个则属于module的管辖范畴。Project和Module是IntelliJ平台管理工程文件的两个概念，类似于Eclipse中的WorkSpace和Project。除此之外，IntelliJ中还包含Facet、SDK等重要元素，它们共同组成这个日益取代Eclipse平台的Project Structure。如图23-13所示。

除了Project和Module级别的build.gradle外，Multi-project还需要一个settings.gradle，这个文件的内容很简单，如下所示：

```
/*settings.gradle*/
include ':app'
```

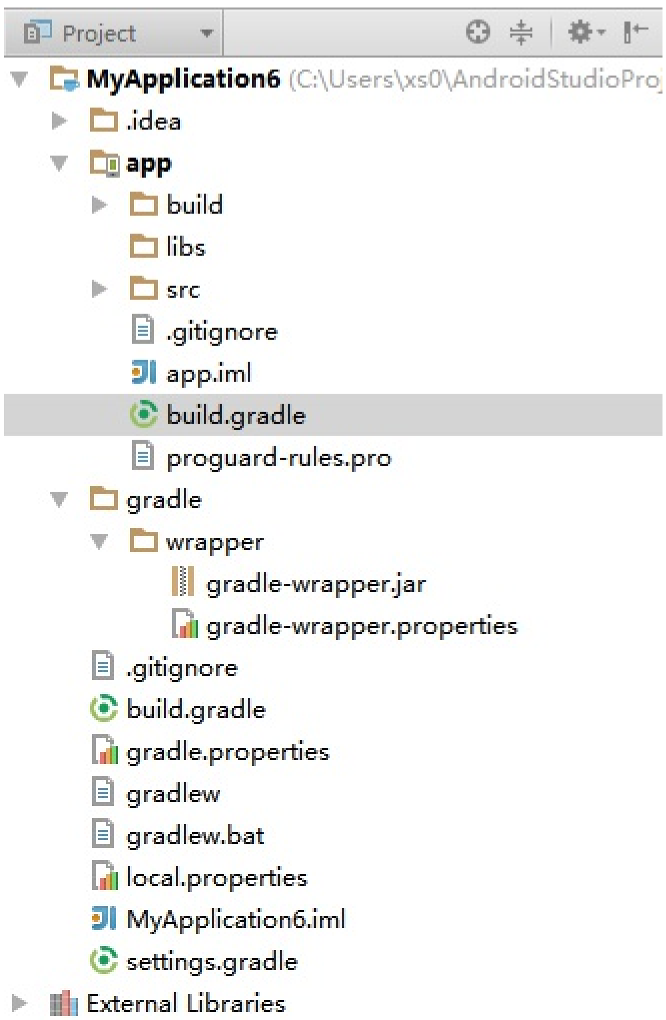

▲图23-12　采用Gradle的默认Android应用工程

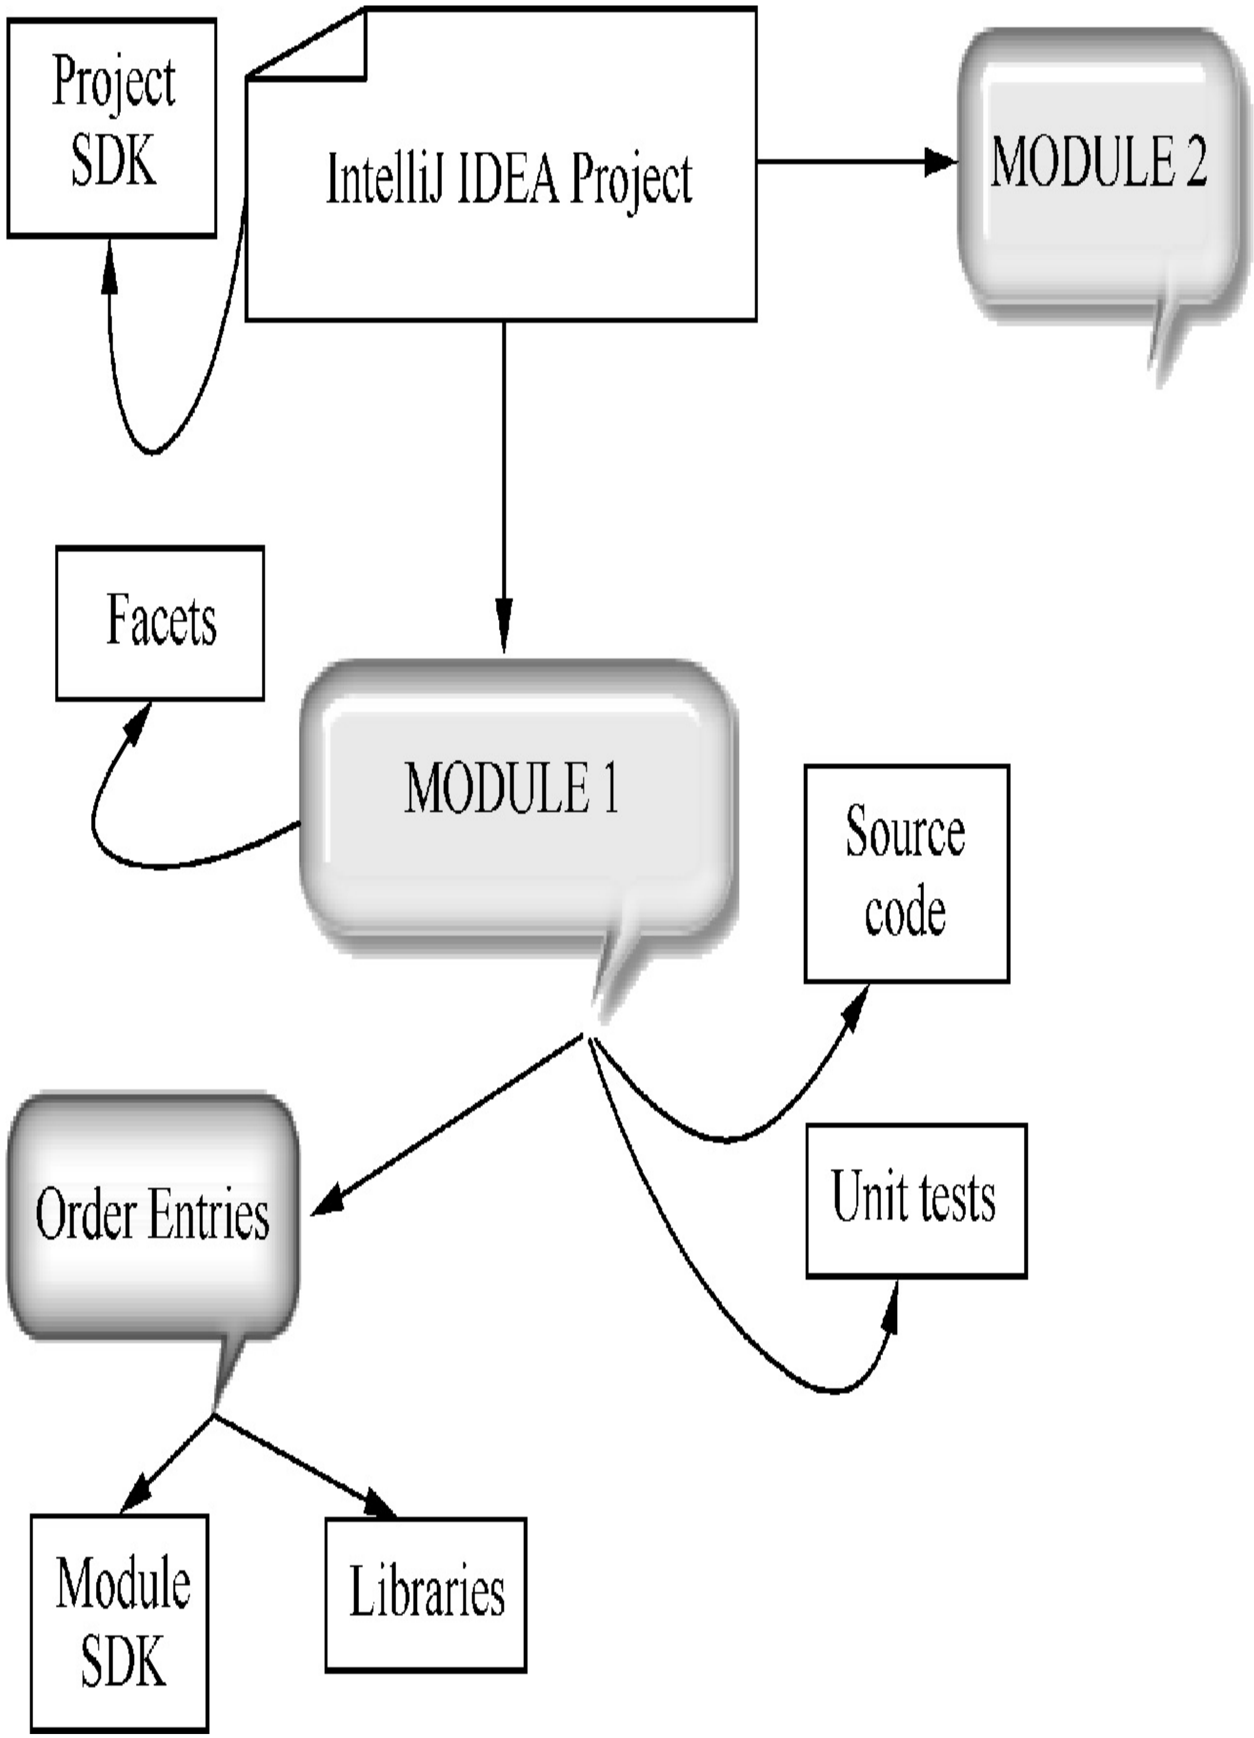
Project SDK
IntelliJ IDEA Project
MODULE 2
Facets
MODULE 1
Source code
Order Entries
Unit tests
Module SDK
Libraries

▲图23-13 IntelliJ平台的Project Structure
（引用自IntelliJ官方文档）

include用于包含想要被编译的所有子项目，我们这个范例中只有一个module，即app。如果有多个子项目的话，会以“,”分隔。

接下来我们再看一下Project层级的Gradle脚本都包含了哪些内容：

```
/*build.gradle (Project Level)*/
buildscript {
    repositories {
        jcenter()
    }
    dependencies {
        classpath 'com.android.tools.build:gradle:1.0.0'

        // NOTE: Do not place your application dependencies here;
        // in the individual module build.gradle files
    }
}

allprojects {
    repositories {
        jcenter()
    }
}
```

这和大家以前用的Ant、Maven等工具应该有显著区别。这种区别实际上会带来两面性：对于初学者来说，可能会不太适应这种变化;对于熟悉Gradle的人来说，这种转变又的确能给他们带来更多的便利。

相信刚接触Gradle的人在看到上述脚本时一定会有一连串的疑问：“buildscript”“allprojects”是什么？它们内部包含的“repositories”是属性值吗？又有哪些其他的属性是可供使用的呢？

还记得我们在前面小节特别提醒大家注意的准则吗？即“Gradle脚本是基于Groovy语言的，因而它一定需要遵循Groovy的语法”。

Gradle为了提高脚本的可读性，在Groovy的基础上做了不少工作。

譬如上面所列的build.gradle中的buildscript实际上是一个函数，其后所跟着的以大括号包含的内容是函数的参数——closure。更具体地说，上述脚本中出现的“buildscript”“allprojects”都属于Script Block。大家可以参考Gradle的官方文档，如图23-14所示。

Build script structure

A build script is made up of zero or more statements and script blocks. Statements can include method calls, property assignments, and local variable definitions. A script block is a method call which takes a closure as a parameter. The closure is treated as a *configuration closure* which configures some delegate object as it executes. The top level script blocks are listed below.

Block	Description
`allprojects { }`	Configures this project and each of its sub-projects.
`artifacts { }`	Configures the published artifacts for this project.
`buildscript { }`	Configures the build script classpath for this project.
`configurations { }`	Configures the dependency configurations for this project.
`dependencies { }`	Configures the dependencies for this project.
`repositories { }`	Configures the repositories for this project.
`sourceSets { }`	Configures the source sets of this project.
`subprojects { }`	Configures the sub-projects of this project.
`publishing { }`	Configures the `PublishingExtension` added by the publishing plugin.

▲图23-14　Build script structure
（引用自https://docs.gradle.org/current/dsl/）

根据Gradle的官方描述，build script是由statements+script blocks组成的。其中statements可以包括函数调用、属性赋值，以及局部变量的定义等；而script block是将闭包作为参数的一个函数调用——这种特性让它们看起来更像是一些配置项，从而提高了可读性。

按照面向对象的编程思想，读者们可能会想这些函数都属于哪些对象呢？这就要得益于Groovy语言的灵活性了。以build.gradle中经常看

到的buildscript为例，它实际上等价于project.buildscript。其中Project是Gradle定义的一个全局的Project对象。换句话说，上述这些函数都属于org.gradle.api.Project中定义的函数。例如buildscript的定义如下：

```
buildscript { }
```

Configures the build script classpath for this project.

The given closure is executed against this project's ScriptHandler. The ScriptHandler is passed to the closure as the closure's delegate.

Delegates to:

ScriptHandler from buildscript

由此可见buildscript的闭包是以一个ScriptHandler对象为delegate的，这也就解释了为什么我们在buildscript中可以使用repositories、dependencies等函数的原因了，因为后者都是在ScriptHandler中定义的，具体可以参考：

https://docs.gradle.org/current/javadoc/org/gradle/api/init

Project中还有不少常用的函数，它们的释义如表23-2所示。

表23-2　Project核心成员函数释义

函数声明	释　义
void buildscript(groovy.lang.Closure closure);	为这个项目配置编译脚本的classpath。ScriptHandler会作为closure的delegate传递给它
void allprojects(groovy.lang.Closure	为这个项目和它所有子项目做配置。

closure);	全局的Project变量会作为closure的delegate传递给它
org.gradle.api.AntBuilder ant(groovy.lang.Closure closure);	用于在build文件中执行ant任务。AntBuild会作为closure的delegate传递给它

void artifacts(groovy.lang.Closure closure);	为这个项目配置published artifacts。ArtifactHandler会作为closure的delegate传递给它。
	官方范例如下：
	
	`configurations {`
	`//declaring new configuration that will be used to associate with artifacts`
	`schema`
	`}`
	
	`task schemaJar(type: Jar) {`
	`//some imaginary task that creates a jar artifact with the schema`
	`}`
	
	`//associating the task that produces the artifact with the configuration`
	`artifacts {`
	`//configuration name and the task:`
	`schema schemaJar`
	`}`

void configurations(groovy.lang.Closure closure);	配置该项目的dependency configuration。ConfigurationContainer会作为closure的delegate传递给它

void dependencies(groovy.lang.Closure closure);	配置该项目的依赖关系。DependencyHandler会作为closure的delegate传递给它
void repositories(groovy.lang.Closure closure);	配置该项目的repositories。RepositoryHandler会作为closure的delegate传递给它

现在大家可以对照上述的分析来理解Android Studio生成的默认工程了。譬如buildscript中的closure语句：

```
repositories {
    jcenter()
}
dependencies {
    classpath 'com.android.tools.build:gradle:1.0.0'
}
```

表示Gradle在build阶段需要到jcenter仓库中查找名为'com.android.tools.build:gradle:1.0.0'的jar包，这是后面我们将要分析的android plugin的实现体。如果不加上这句依赖的话，Gradle将无法正常生成DAG，并报错，如图23-15所示。

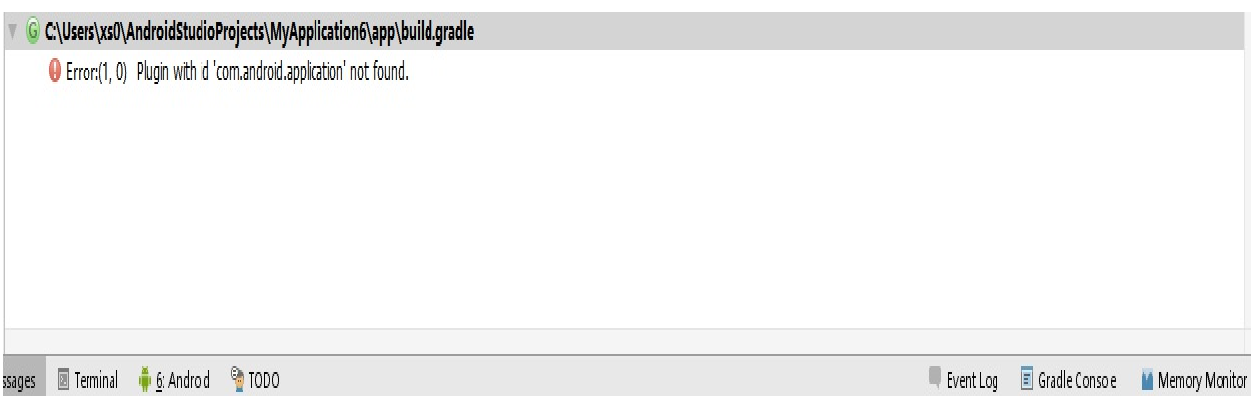

▲图23-15 报错

“allprojects”则预先设置了jcenter做为所有子项目的依赖关系

包存储仓库。另一个常见的仓库是maven，对应的函数是mavenCentral，开发者可以根据自己的实际需求进行选择。

接下来我们再分析一下上述范例工程中sub-project的build file，如下所示：

```
apply plugin: 'com.android.application'

android {
    compileSdkVersion 21
    buildToolsVersion "21.1.1"

    defaultConfig {
        applicationId "com.example.xs0.myapplication"
        minSdkVersion 15
        targetSdkVersion 21
        versionCode 1
        versionName "1.0"
    }
    buildTypes {
        release {
            minifyEnabled false
            proguardFiles getDefaultProguardFile('proguard-androi
        }
    }
}

dependencies {
    compile fileTree(dir: 'libs', include: ['*.jar'])
    compile 'com.android.support:appcompat-v7:21.0.2'
}
```

上面这个build.gradle很明显是针对Android工程的，它使用到了id值为“com.android. application”的插件，并通过apply函数把它引入到Gradle的脚本中。这个plugin对应的jar包是我们前面看到的'com.android.tools.build:gradle:1.0.0'。而apply则属于org.gradle.api.Project提供的函数，只有通过调用这个函数来显式声明我们需要用到的插件名，才能保证插件中提供的各种函数和属性能在Gradle中正常使用。

大家应该已经猜到了，上述脚本中的“compileSdkVersion 21”和“buildToolsVersion "21.1.1" ”等看似参数配置的写法实际上也是函数调用。这些函数都是在Android的Gradle插件中声明的。大

家可以通过如下命令获取到源代码，并自行阅读分析：

```
$ repo init -u https://android.googlesource.com/platform/manifest
$ repo sync
```

另外，Gradle的源码下载与编译流程，也可以参见其官方网站的介绍，我们这里不做赘述：

https://docs.gradle.org/current/userguide/userguide.html

上面所说的buildscript函数的源码声明如下所示：

```
/*subprojects/core/src/main/groovy/org/gradle/api/Project.java*/
public interface Project extends java.lang.Comparable<org.gradle.
gradle.api.plugins.ExtensionAware, org.gradle.api.plugins.PluginA
    java.lang.String DEFAULT_BUILD_FILE = "build.gradle";
    java.lang.String PATH_SEPARATOR = ":";
    java.lang.String DEFAULT_BUILD_DIR_NAME = "build";
    java.lang.String GRADLE_PROPERTIES = "gradle.properties";
    java.lang.String SYSTEM_PROP_PREFIX = "systemProp";
    java.lang.String DEFAULT_VERSION = "unspecified";
    java.lang.String DEFAULT_STATUS = "release";
    …
    void buildscript(groovy.lang.Closure closure);
    …
}
```

当然，对于普通开发人员来讲，我们学习Gradle的最主要目的是了解清楚如何配置和使用它，从而让它更好地为Android应用程序开发过程服务。只有先把“知其然”做好了，才有可能进一步地“知其所以然”。

第24章

软件版本管理

对于Android这种规模的大项目，软件版本管理非常重要，因而我们首先为大家介绍其中的相关知识。当然，如果读者对这部分内容已经很熟悉，可以直接略过并进入下一章节的学习。

24.1　版本管理简述

20世纪计算机发展的早期，软件项目的普遍开发特点如下（有点类似于家庭式作坊）：

- 开发人员数量很少，甚至往往只是由个人单独完成的；
- 项目所涉及的源文件不多，完成的功能相对单一；
- 开发人员之间的沟通通常是面对面的。

在这种情况下，工作人员完成一个软件项目的研发并不需要太多交互。因此他们可以独立编写、修改、调试代码，并在个人的机器上进行项目源文件的存储和管理。这个阶段还没有出现软件版本管理的概念，开发过程存在一定的主观随意性——软件源码的管理完全取决于开发人员自身的专业素养和研发习惯。

随着软件行业的不断发展，软件开发复杂度越来越大，而且项目源码的数量也呈现出指数级增长。比如1991年Linux的0.11版本发布时，其代码总量不过2万多行；而到了2.6.0版本发行时，这个数字已经变成了近6百万——只由一个人或者几个人来完成一个大型的现代软件项目已经成为天方夜谭。调查资料显示，Windows 7操作系统项目的技术开发人员超过了2000人，并分布在世界各地。而作为开源项目的翘楚，Linux也早已不再是由Linus Torvalds一人来维护升级。全球每天都有新人不断加入这一伟大项目的开发工作中。

面对如此庞大的开发团队，有如下几个问题不可避免：

- 如何做好这么多开发人员的项目分工；
- 如何协调他们之间的交互；
- 如何有效地把每个人的工作成果快速体现在整个项目上；
- 如何处理好冲突，如多个开发人员同时对同一个文件进行修改；
- 如何做文件的历史追踪和回退；
- 如何做好每个源文件、每个版本的信息记录工作。

以上这些疑问都是一个版本管理系统所必须要解决的。Android系统首选Git作为版本管理的工具——虽然它是一个功能相当强大的版本管理系统，但不少人抱怨其使用方法过于烦琐，易用性比较差。为此

Android系统又特别提供了一个方便的小工具，即Repo。本书编译章节对此已经有过介绍，不清楚的读者可以回头复习。

24.2 Git的安装

一款杰出开源工具的先天特质，很大程度上取决于其创始者的背景与个性——就好比一个新生儿流淌的血液中，与生俱来便继承了其父母辈们的优良与糟粕基因一样。开源项目并不是为赢利而生的，很多情况下是业余爱好者或技术狂热者的杰作，因此更大程度上可以摆脱商业的束缚，影射出技术者本身的专业素养与思维习惯。

Git和Linux“系出同门”，都出自于Linus Benedict Torvalds之手。英文俚语中，“git”这个单词代表了“无用的人”。这位出生于荷兰的技术领袖对Git的解释是：

```
“I'm an egotistical bastard, and I name all my projects after mys
```

这是Linus的一种自嘲，不过也隐约体现出了Git所想表达的含义——简单，傻瓜式的管理方式。

由于Git起初是用于取代Bitkeeper（Bitkeeper是Linux早期采用的版本控制系统，直到2005年才和Linux社区脱离关系。这其中的恩恩怨怨直接触发了Linus对Git的开发）来维护和管理Linux Kernel的，因此其很多特性都具有Linux的影子，而对Windows等其他操作系统的支持不太好。后来得益于Git的广泛应用，一些类似于msysgit的工具也开始流行起来，以保证Git在Windows环境下能正常运行。

24.2.1 Linux环境下安装Git

和大部分其他工具一样，Linux环境中的Git安装分为两种方式，即源代码编译安装和“Package包”直接安装。

1. 源代码编译安装Git

这种方法相对于安装包要麻烦一些，而且容易出错。如果读者只是想使用Git这个工具，并不打算研究其源码实现，那么建议采用下一小节的方式进行便捷安装。

如果选择从源代码安装，首先要从官网上下载Git源码及它的依赖包。如下所示：

- Git源代码. http://git-scm.com/download;
- Curl.http://curl.linux-mirror.org/;
- Zlib.http://www.zlib.net/;
- Openssl. http://www.openssl.org/;
- Expat. http://expat.sourceforge.net/;
- Libiconv. http://www.gnu.org/software/libiconv/。

假如操作系统中有yum（比如Fedora）或者apt-get（Debian，Ubuntu环境中）工具，那么还可以选择以下方式来安装依赖包：

```
$ yum install curl-devel expat-devel gettext-devel openssl-devel
$ apt-get install libcurl4-gnutls-dev libexpat1-devgettext libz-d
```

Git源码下载完成后，我们就可以进行编译和安装了。根据官方的建议，这个过程如下：

```
$ tar -zxf git-1.7.2.2.tar.gz
$ cd git-1.7.2.2
$ make prefix=/usr/local all
$ sudo make prefix=/usr/local install
```

这样我们就完成Git的源代码安装了。如果需要的话，还可以通过Git来管理Git源码。如下：

```
$ git clone git://git.kernel.org/pub/scm/git/git.git
```

2．直接安装Git

这种方式比较方便，适用于一般的Git使用者。

对于Linux用户（安装有yum工具的系统）：

```
$ yum install git-core
```

对于Linux用户（安装有apt-get工具的系统）：

```
$ apt-get install git-core
```

对于Mac用户，又可细分为以下两种方法。

- 图形化的安装方式。下载地址是:

```
http://code.google.com/p/git-osx-installer
```

- 通过MacPorts安装。指令如下:

```
$ sudo port install git-core +svn +doc +bash_completion +gitweb
```

24.2.2 Windows环境下安装Git

Windows环境下安装Git也有两种方式。

其一是基于Cygwin（http://www.cygwin.com/）。

其二是直接下载安装msysGit。

其中msysGit和普通的Windows应用程序的安装并没有区别。其提供的以“exe”为后缀名的安装包下载地址是:

```
http://code.google.com/p/msysgit/downloads/list
```

安装界面如图24-1所示。

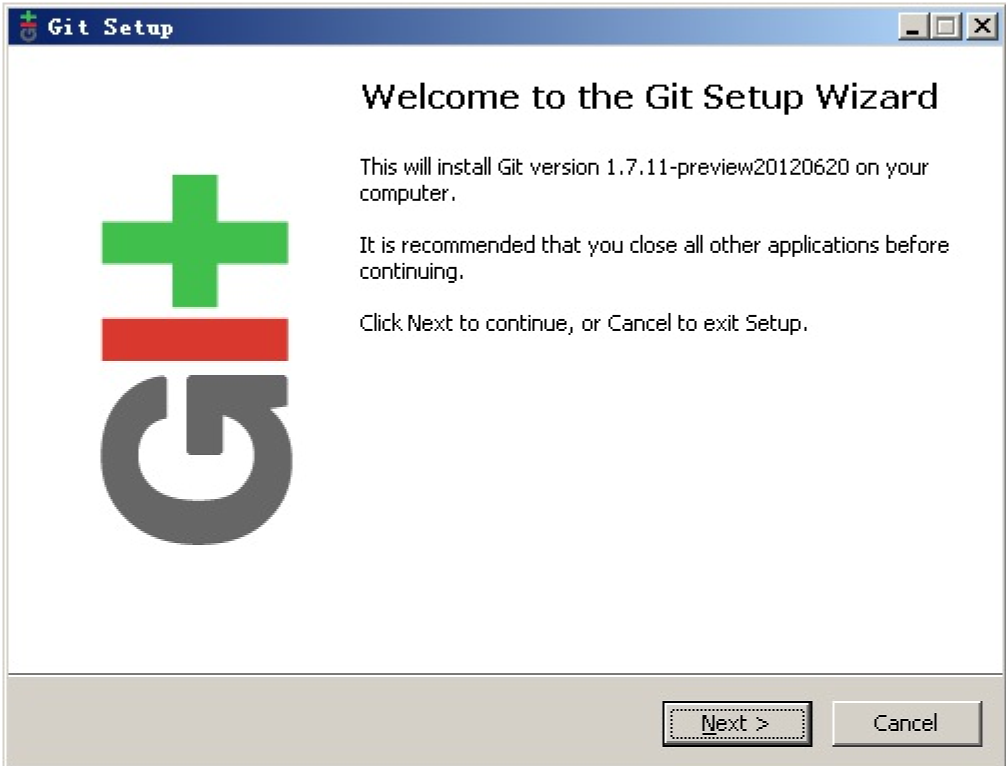

▲图24-1　安装界面

它有两个工作界面可供不同使用习惯的用户挑选，对比图如图24-2所示。

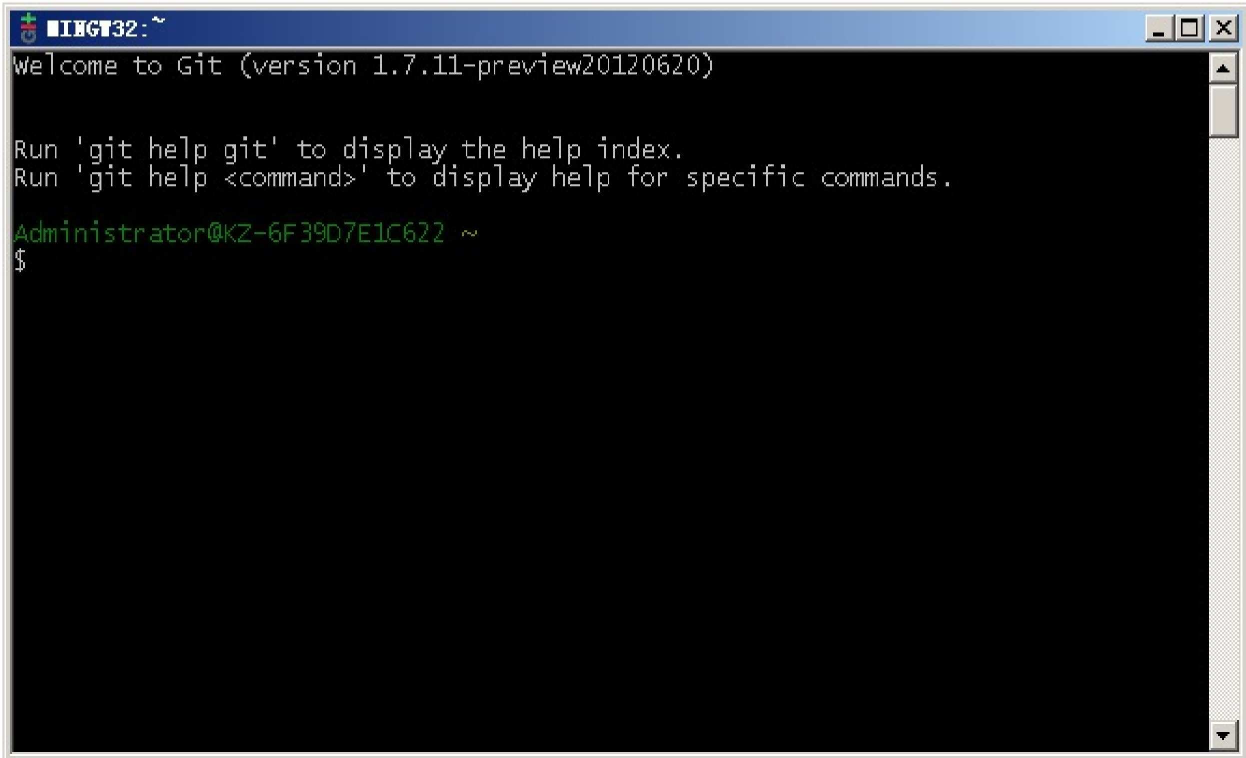

Bash界面

GUI界面 ▲图24-2　对比图

24.3 Git的使用

24.3.1 基础配置

Git要求的配置并不多，使用也相对简单。下面我们进行简单介绍。

1．git config

“git config”为用户配置Git提供了统一的接口。针对不同级别的对象（系统级、用户级和项目级），Git都可以分别进行配置。这几个级别的配置将根据优先级依次覆盖，有点类似于C++中的继承关系，即一方面“子类”继承了“父类”的大多数属性，另一方面“子类”又可以重写“父类”的某些特性。

各级别的配置文件分别存储在。

- /etc/gitconfig. 系统级配置，对所有用户和项目有效。我们在使用git config时如果传入--system选项，就可以配置系统级别文件。
- ～/.gitconfig. 用户级配置，对当前用户有效。我们在使用git config时如果传入--global选项，就可以对用户级配置进行修改。
- .git/config. 项目级配置，只对这个项目有效，因此配置文件放置于项目的git目录中。

根据上面的分析，我们知道.git/config中的信息将覆盖～/.gitconfig，而后者又将覆盖/etc/gitconfig中的配置。

2．个人信息

Git要求每个用户都提供个人信息，这样就可以鉴别出代码提交者的身份。具体内容包括用户名和邮箱地址。比如：

```
$ git config --global user.name "Xuesen Lin"
$ git config --global user.email xslin@ThinkingInAndroid.com
```

用户可以根据需求来加上--global等选项。

3．编辑器选择

Git允许用户自由选择合适的编辑器。当它需要用户输入信息时，会自动调用事先设置好的编辑器类型。比如你习惯使用emacs进行文字编辑，那么可以用以下命令进行设置：

```
$ git config --global core.editor emacs
```

4．差异比较工具选择

“差异比较”在Git中是个常用的操作，而且用户同样可以定制自己喜欢的工具。比如以下命令会将其设置为vimdiff：

```
$ git config --global merge.tool vimdiff
```

根据官方的说明，Git除了可以支持kdiff3，tkdiff，meld，xxdiff，emerge，vimdiff，gvimdiff，ecmerge和opendiff等差异分析工具外，还能匹配用户自己开发的类似工具。读者可以参阅官方文档来了解详情。

5．配置信息列表

当完成配置后，用户可用以下命令来查看目前已经设置好的各项值：

```
$ git config --list
user.name=Xuesen Lin
user.email=xslin@ThinkingInAndroid.com
color.status=auto
color.branch=auto
color.interactive=auto
color.diff=auto
```

24.3.2　新建仓库

对于SVN，CVS等集中式的版本控制系统，整个项目只有一个仓库（repository）。这样的集中式管理有利于项目文件的统一维护，不过缺点也显而易见，即用户必须连上服务器才能开始提交。

Git属于分布式的版本管理系统，每个开发者都可以单独拥有完整

的本地仓库。这就意味着提交代码的动作在很大程度上可以不依赖于服务器——开发者先离线提交到本地仓库中，最后再统一push到服务器上。因为这一特点，Git的提交动作很快，几乎瞬间就能完成。当然，不论什么系统都有其最佳的适用场合，并不存在绝对的优劣之分，读者要根据自己的实际项目需求来决定采用何种系统。

仓库的新建具体分为两种，即本地新建一个空仓库或者克隆一个已有仓库。

1．本地新建仓库

我们来举个例子进行说明。

假设有一个简单的工程项目，包括的文件及目录结构如下所示。

```
./
|-- src
      |----- main.c
      |----- utility.c
      |----- utility.h
      |----- Makefile
|-- bin
|-- Makefile
|-- Readme.txt
```

如果我们要在本地为这个项目建立一个仓库，可以在其根目录下执行以下命令。

```
$ git init
```

得到的Git返回信息为：

```
Initialized empty Git repository in /home/android/Work/ThinkingInAndroid/GitTest
/.git/
```


```
Initialized empty Git repository in /home/android/Work/ThinkingInAndroid/GitTest
/.git/
```


说明我们已经成功创建了一个本地仓库。这时会发现在根目录下多了一个.git目录，其文件结构及作用如下：

```
.git
|-- branches  #新版本不再适用，一般是空的
|-- hooks     #hooks脚本文件
|-- info      #指定需要忽略的文件
|-- objects   #存储Git的4个重要的数据对象，后面小节有详细解释
|-- refs      #分支指向的提交
|-- config    #设置文件，可以参见本章中的配置小节
|-- description #一些项目的描述信息
|-- HEAD    #指出当前在哪个分支
```

这些文件都是Git进行版本管理控制所需的信息，后面的原理小节中我们还会进一步分析。

2. 克隆已有仓库

因为是克隆，相当于把一个已经存在的项目镜像了一遍。

比如我们在本书的基础篇中曾讲解过如何下载Android系统的源码。其中克隆kernel/common的命令如下：

```
git clone git://android.git.kernel.org/kernel/common.git
```

克隆一个git项目的通用格式为：

```
git clone [--template=<template_directory>]
[-l] [-s] [--no-hardlinks] [-q] [-n] [--bare] [--mirror]
[-o <name>] [-b <name>] [-u <upload-pack>] [--reference <reposito
[--separate-git-dir <git dir>]
[--depth <depth>] [--[no-]single-branch]
[--recursive|--recurse-submodules] [--] <repository>
[<directory>]
```

Git支持多种数据传输协议，上面的范例中就用到了其中的git://协议。更多协议（如SSH，HTTP/S等）的详细解释，读者可以参阅官方文档进行了解。对于一般的用户来说，只要知道如何使用这些协议即可。

执行了克隆命令后，通常情况下可以得到类似下面的提示信息（它给出了所有对象的个数、下载进度以及项目文件的解析进度等）。

```
Cloning into 'input'...
remote: Counting objects: 2437563, done.
remote: Compressing objects: 100% (373783/373783), done.
remote: Total 2437563 (delta 2040660), reused 2435598 (delta 2039738)
Receiving objects: 100% (2437563/2437563), 491.78 MiB | 315 KiB/s, done.
Resolving deltas: 100% (2040660/2040660), done.
Checking out files: 100% (38572/38572), done.
```

24.3.3　文件状态

Git管理下的文件状态如图24-3所示。

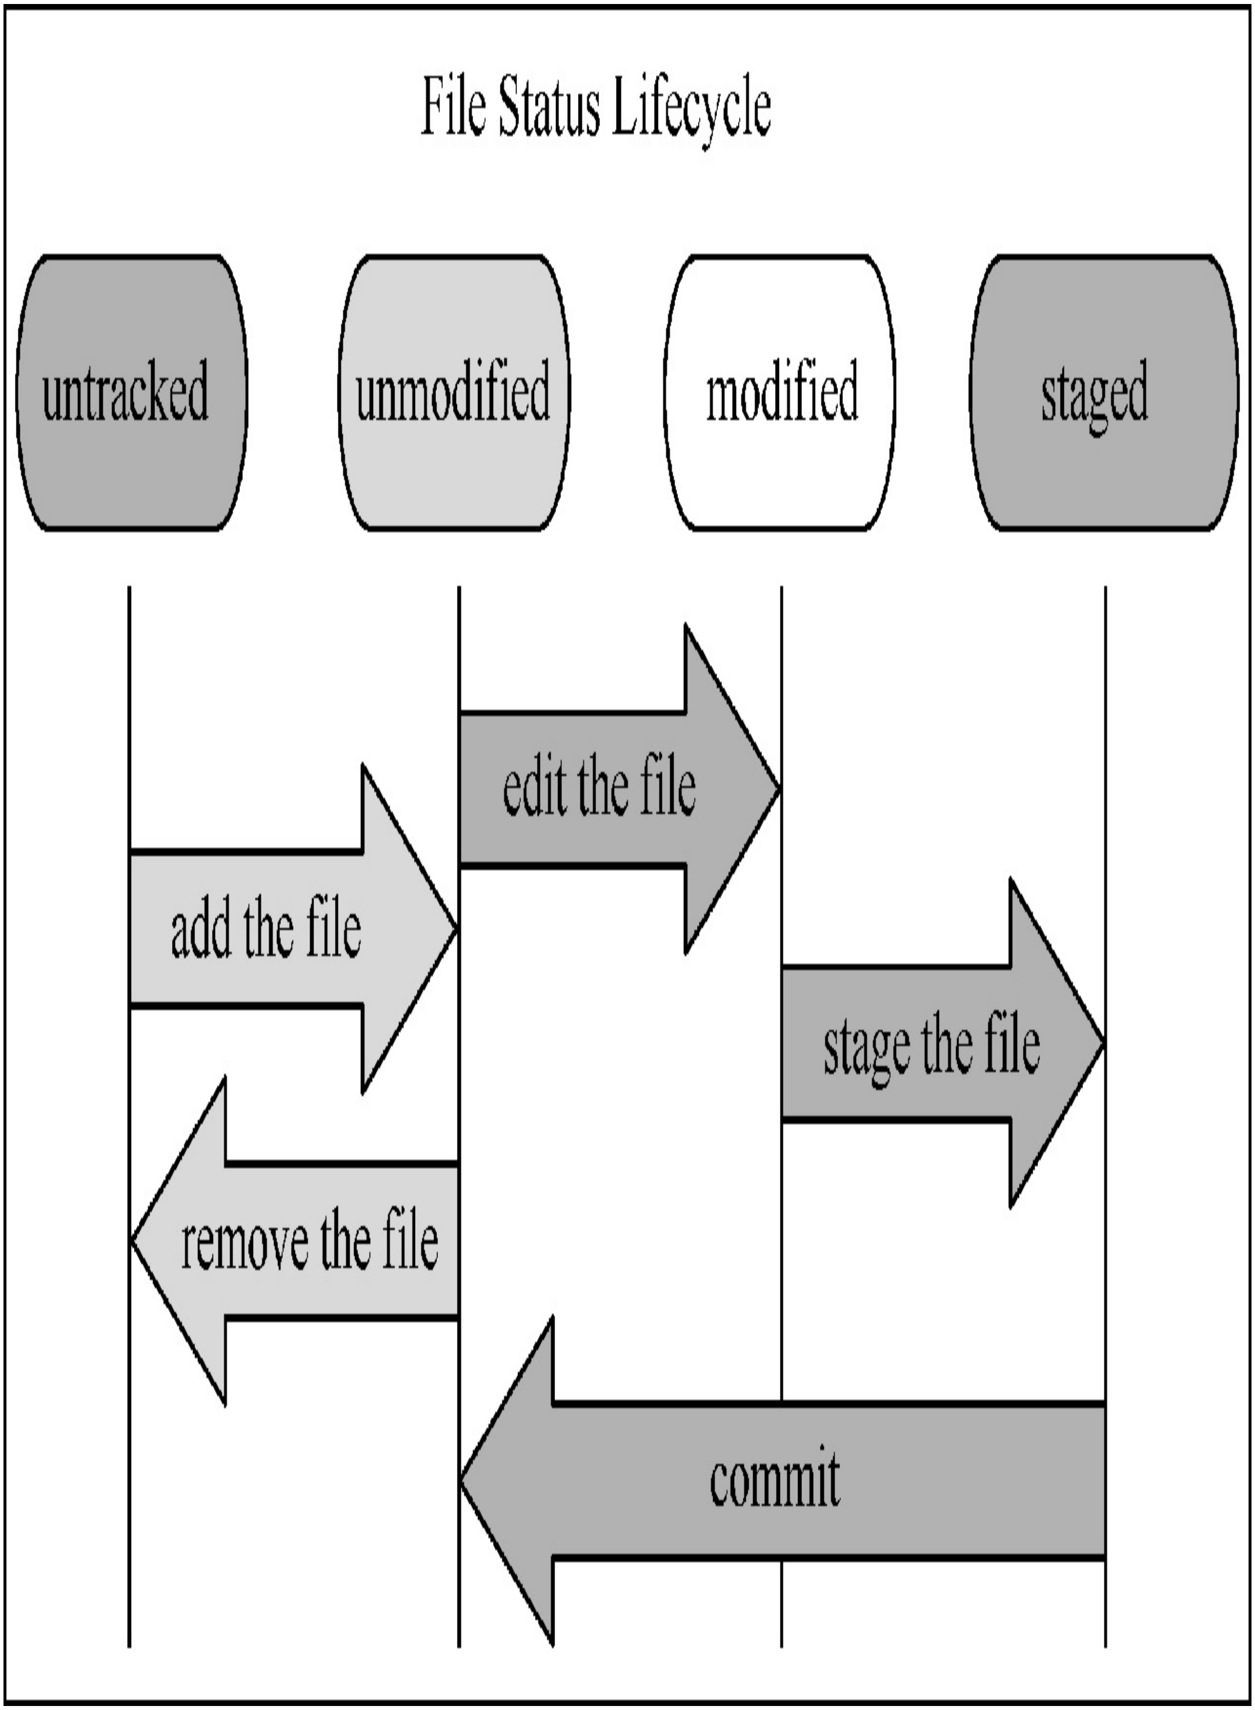
File Status Lifecycle
untracked
unmodified
modified
staged
edit the file
add the file
stage the file
remove the file
commit

▲图24-3　Git管理下的文件状态
（注：引用自http://git-scm.com/book。）

在Git版本管理系统中，每个文件都有其特定的状态。我们分别来解释这些状态的含义。

- 未跟踪状态（untracked）

说明这个文件还没有纳入Git的管理范畴。除此之外的其他3种状态都可以划归为“已跟踪状态”。显然，对于一个刚刚克隆完成的项目，它的所有文件都处于已跟踪状态。

- 未修改状态（unmodified）

说明这个文件已经在Git的管理下，而且相对于上一次提交没有任何修改。

- 已修改状态（modified）

说明这个文件相对于上一次提交有了新的变化，而且它还没有被暂存。

- 已暂存状态（staged）

只有当一个文件被stage后，它才能在下一次的commit动作中被提交。提交过后，它又将变成unmodified状态。

明白了这几个状态的含义后，我们再来看看如何查询某个文件的当前状态。只要执行以下命令即可。

```
git status [<options>...] [--] [<pathspec>...]
```

比如我们前一小节新建的Git范例项目中，执行查询命令后得到的信息如下。

```
# On branch master
#
# Initial commit
#
# Untracked files:
#   (use "git add <file>..." to include in what will be committed)
#
#       Makefile
#       Readme.txt
#       bin/
#       src/
nothing added to commit but untracked files present (use "git add" to track)
```

可以看到，所有的文件/目录都处于未跟踪状态。

我们可以通过如下命令把一个文件/目录加入Git的管理中：

```
git add [-n] [-v] [--force | -f] [--interactive | -i] [--patch |
[--edit | -e] [--all | [--update | -u]] [--intent-to-add | -N]
[--refresh] [--ignore-errors] [--ignore-missing] [--]
[<filepattern>...]
```

例如执行如下命令：

```
git add Makefile
```

此时工程文件的状态发生了一定变化，如下所示。

```
# On branch master
#
# Initial commit
#
# Changes to be committed:
#   (use "git rm --cached <file>..." to unstage)
#
#       new file:   Makefile
#
# Untracked files:
#   (use "git add <file>..." to include in what will be committed)
#
#       Readme.txt
#       bin/
#       src/
```

由此可知，Makefile这个文件已经从Untracked状态转型成功。

对于目录而言，git add则会将其所包含的所有文件/子目录都加入Git。

比如执行：

```
git add src
```

新的状态如下所示。

```
# On branch master
#
# Initial commit
#
# Changes to be committed:
#   (use "git rm --cached <file>..." to unstage)
#
#       new file:   Makefile
#       new file:   src/Makefile
#       new file:   src/main.c
#       new file:   src/main.o
#       new file:   src/utility.c
#       new file:   src/utility.h
#       new file:   src/utility.o
#
# Untracked files:
#   (use "git add <file>..." to include in what will be committed)
#
#       Readme.txt
#       bin/
```

如果要删除已经add的文件，可以使用：

```
git rm [-f | --force] [-n] [-r] [--cached] [--ignore-unmatch] [--
```

在进行这一步操作时，要格外小心——如果你只是想解除文件与Git的管理关系，那么要加上--cached选项，否则会把源文件删除掉。关于更多注意事项和使用方法，可以使用git帮助进行了解：

```
git help [-a|--all|-i|--info|-m|--man|-w|--web] [COMMAND]
```

24.3.4　忽略某些文件

在实际的项目开发过程中，往往有很多中间文件，如编译出来的.o、log跟踪文件等。一方面，这些文件并不需要进入版本树中；另

一方面，如果不把它们add进Git，那么每次执行git status时又都会出现untracked文件提示，这显然也不太方便。

为了避免这种情况，我们可以在项目根目录下创建一个名为“.gitignore”的文件来记录那些不想被跟踪的文件。“.gitignore”文件的书写格式如下：

- 以注释符号#开头的行都会被Git忽略。
- 遵循标准的glob模式匹配。

比如上面例子中的bin文件夹处于untracked状态，如果想忽略此目录中的所有文件，可以通过编辑“.gitignore”文件来达到目的。范例如下：

```
#This line will be ignored
bin/
```

再次执行状态查询命令，会发现bin目录已经不再被追踪显示。如下所示。

```
# On branch master
#
# Initial commit
#
# Changes to be committed:
#   (use "git rm --cached <file>..." to unstage)
#
#       new file:   Makefile
#       new file:   src/Makefile
#       new file:   src/main.c
#       new file:   src/main.o
#       new file:   src/utility.c
#       new file:   src/utility.h
#       new file:   src/utility.o
#
# Untracked files:
#   (use "git add <file>..." to include in what will be committed)
#
#       .gitignore
#       Readme.txt
```

24.3.5　提交更新

“提交更新”是把项目中被修改的文件保存进本地仓库的一个重要动作。不过要特别注意，只有那些被staged的文件才会被提交。

提交命令很简单，格式如下：

```
git commit [-a | --interactive | --patch] [-s] [-v] [-u<mode>] [-
[-F <file> | -m <msg>] [--reset-author] [--allow-empty]
[--allow-empty-message] [--no-verify] [-e] [--author=<author>]
[--date=<date>] [--cleanup=<mode>] [--status | --no-status]
[-i | -o] [--] [<file>...]
```

执行命令后，Git会自动调用文本编辑器（配置小节里讲解过如何设置默认的编辑器类型）来让用户描述本次的提交操作（比如为什么提交、有哪些更改等）。例子如下所示。

```
The first commit
# Please enter the commit message for your changes. Lines starting
# with '#' will be ignored, and an empty message aborts the commit.
#
# Committer: Xuesen Lin <android@android-VirtualBox.(none)>
#
```

完成操作后，Git会提示最终的提交结果。如下所示。

```
[master (root-commit) 0df9ec6] The first commit
 Committer: Xuesen Lin <android@android-VirtualBox.(none)>
Your name and email address were configured automatically based
on your username and hostname. Please check that they are accurate.
You can suppress this message by setting them explicitly:

    git config --global user.name "Your Name"
    git config --global user.email you@example.com

After doing this, you may fix the identity used for this commit with:

    git commit --amend --reset-author

 7 files changed, 30 insertions(+), 0 deletions(-)
 create mode 100755 Makefile
 create mode 100755 src/Makefile
 create mode 100755 src/main.c
 create mode 100644 src/main.o
 create mode 100755 src/utility.c
 create mode 100755 src/utility.h
 create mode 100644 src/utility.o
```

24.3.6 其他命令

Git支持的命令相当丰富，几乎覆盖了版本管理和查询的方方面面。下一小节的原理分析中我们还会根据场景需要再对其他常用命令进行讲解。另外，建议读者通过“man git”或者“git －help”来获取更多信息（特别是一些高级命令的使用方法）。

24.4　Git原理简析

无论多么复杂的系统，总是基于某一个（或几个）核心原理扩展开的。这个基石就像我们散文写作的中心思想一样，可以有效地保证即使文章的“形”再散，都不会影响到“神聚”。本书基础篇里读者曾系统地学习了Android的编译系统——它乍看起来相当庞大可怕，但只要抽丝剥茧，就会发现其实它所基于的make依赖原则相当简明易懂。

版本管理系统也类似。因此，首先我们要理解它所要做的核心任务是什么。

很显然，就是“版本的管理”。或者更具体地讲，就是：

针对每个项目文件各个修改版本的统一有序的管理。

下面我们画一个抽象图来帮助读者理解这一“中心思想”。

假设有一个项目工程，其文件关系如下。

```
A
|-- B
     |----- D
|-- C
     |----- E
     |----- F
```

那么经过多次提交操作后，版本管理系统中的抽象图可能如图24-4所示。

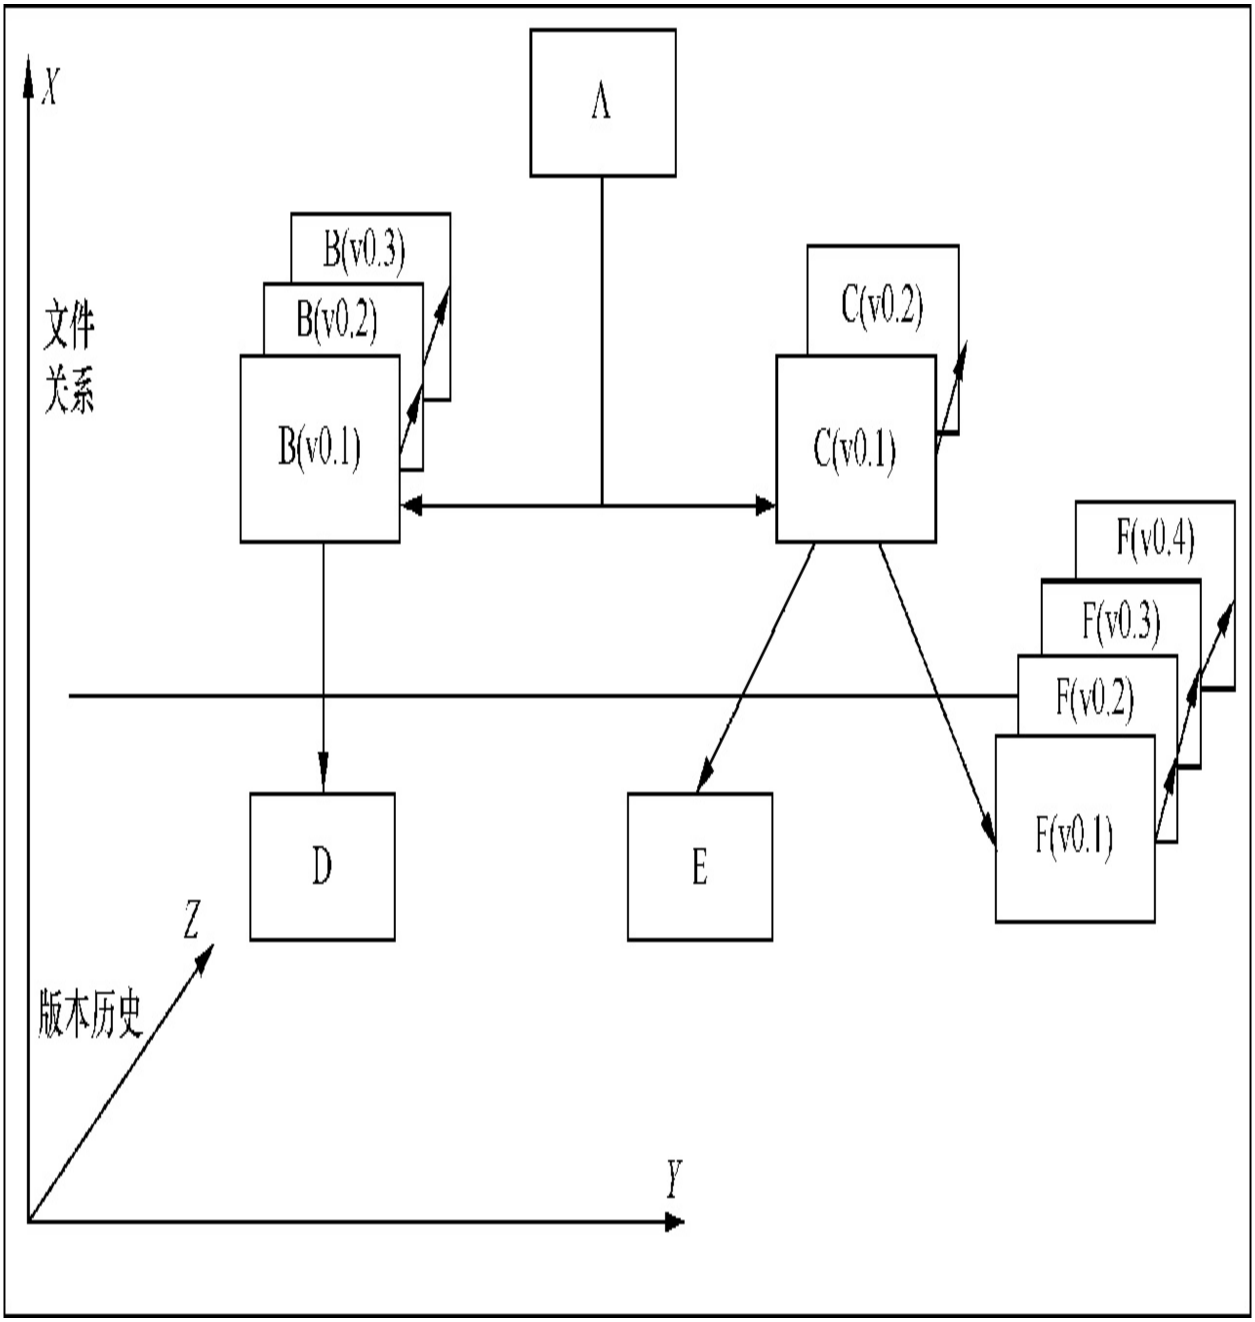

▲图24-4　版本管理系统的抽象图

下面来解释下这张图的含义。

- 首先它是一张三维立体图，其x、y坐标系组成的平面代表了项目文件的构成以及它们之间的关系。比如A包含了B和C，而C又进一步包含了E和F。z坐标给出了每个文件的版本修改历史，其中括号中

的v表示version，后面的数字随每次修改记录而递增。

- 要特别强调一下，这是一张某一特定时刻下的版本管理图。换句话说，随着时间的推移，管理图是在不断变化的。比如源文件的修改、新增或者删除，都会导致整个系统图的更新。
- 在实际版本管理系统的实现中，每一个节点往往代表了一个具体的文件或者目录。比如在这个例子中，A、B、C 3个节点显然是目录，而其他节点可能是目录或者文件。
- 对于同一个节点的不同版本，有的版本管理系统只会记录它们之间的差异部分，而有的系统则会完整记录文件的每一个版本。举个例子，F节点目前已经有4个版本。如果只记录每个版本间的差异，那么我们如果想取得F的v0.2版本文件，则需要和v0.1文件进行差异比较，再还原出整个源文件。而如果文件的每个版本都有单独的记录，那么可想而知提取指定版本的文件内容就会快很多——缺点就是会占据一定的存储空间，即典型的“以空间换时间”的做法。

明白了版本管理系统的基础知识后，我们接下来对照Git来看看它是怎么做的。

24.4.1　分布式版本系统的特点

我们一直在强调Git是一种分布式的版本管理系统（DVCS）。与之相对的，就是集中式的管理系统（CVCS），如图24-5所示。那么，这两种机制间有什么本质的区别呢？通过对前几小节内容的了解，相信读者已经有了初步的概念。

如图24-5所示，集中式的版本控制系统需要一台服务器的支持才能完成提交、合并等重要操作。这就意味着开发者必须与服务器取得连接才能正常工作。如果服务器发生故障，很可能会导致整个项目开发进展停滞。

要特别指出的是，Git虽然是分布式的管理系统，但并不意味着它不能以集中式的控制方式工作；相反，图24-5所示的工作流也是Git的一种常用形式。正如我们一直在强调的，问题不在于选择哪个工具——这不是目的，真正的目的是根据实际项目需求来选择最合适自己的工具。

除了集中式的管理外，Git的工作流形式还可以有很多种。因为每个开发者都并非纯粹的“消费者”，他们除了取得远程仓库上已有的代码外，自己也可以成为“生产者” ——通过将自己设为共享仓库来让其他人获取到他们编写的代码。

接下来我们引用Git官方文档上的一个例子来分析其他两种比较常用的Git工作流方式。

第一种方式通常被运用于像GitHub（https://github.com/）这样的网站，称为“管理员工作流”（Integration-Manager Workflow）。

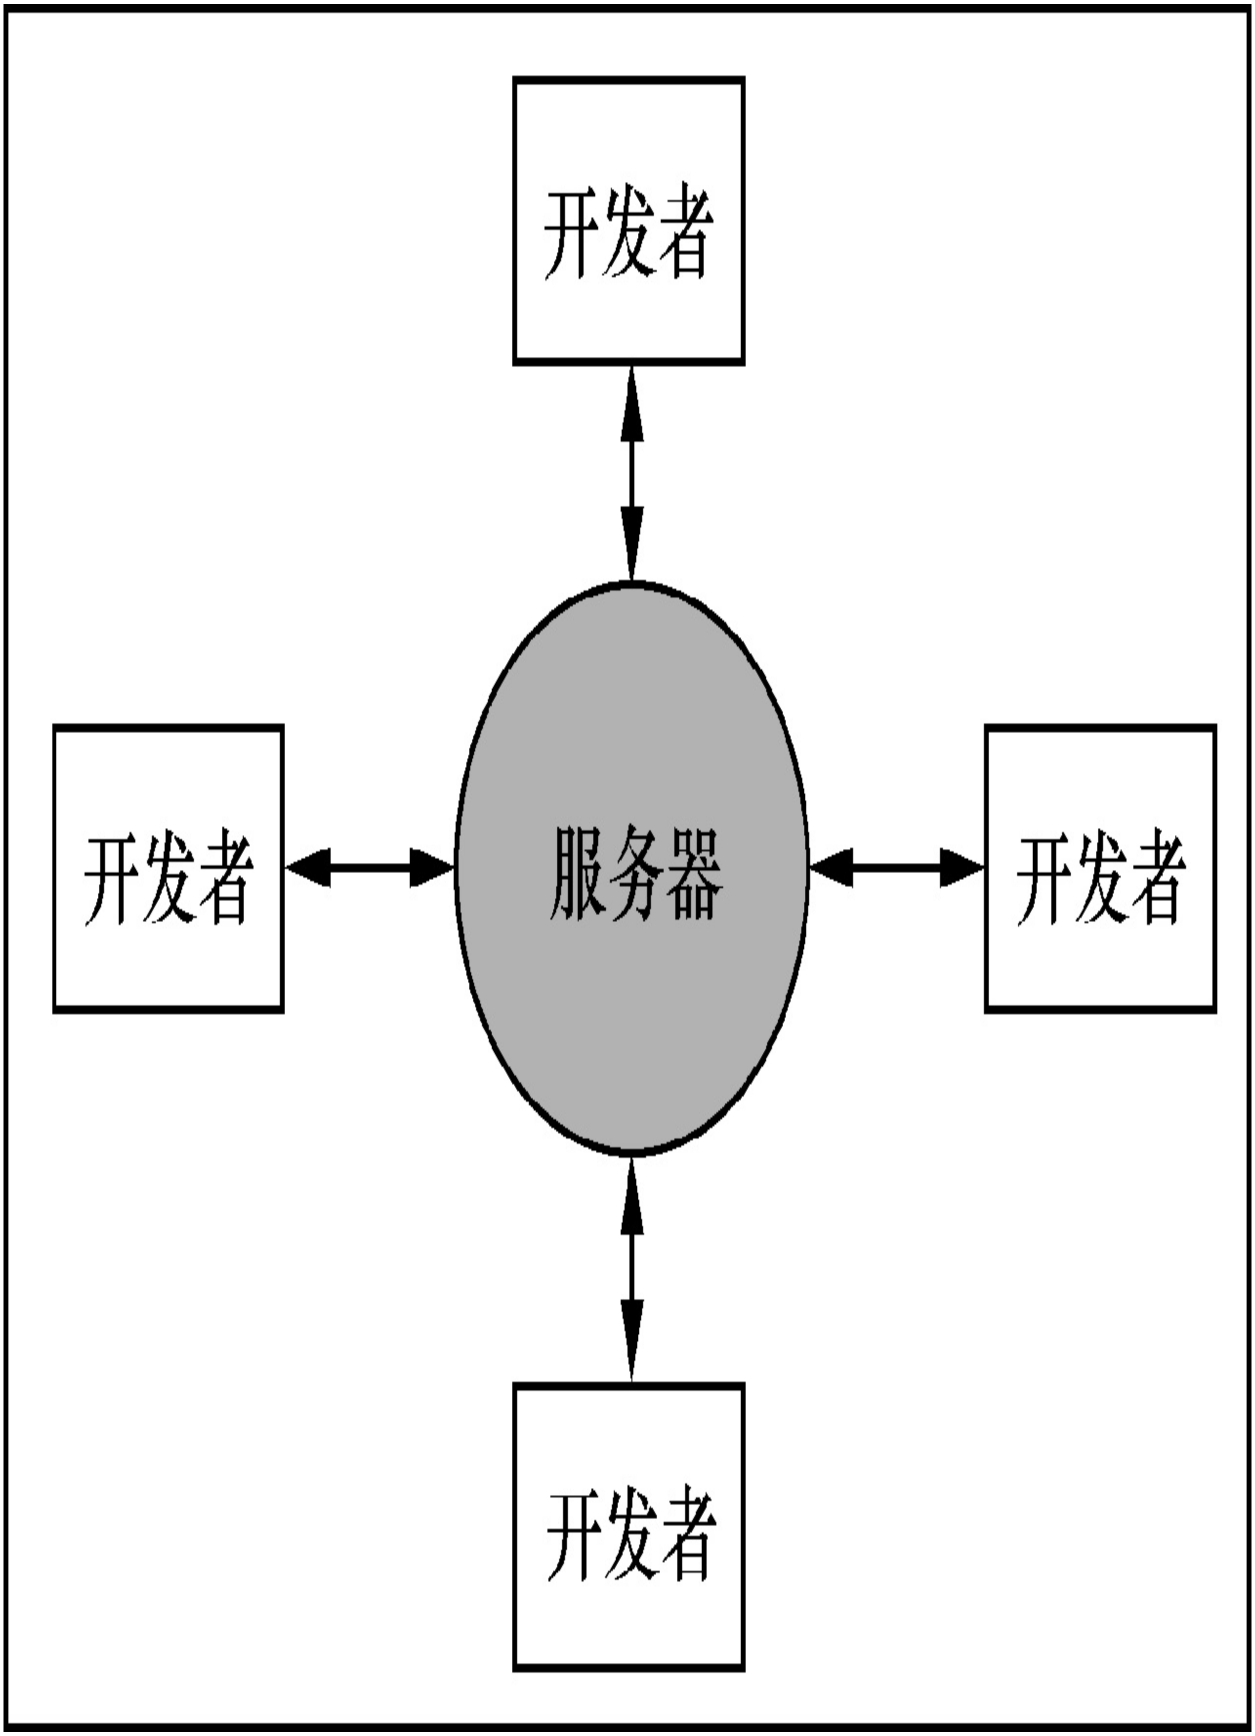
开发者
开发者
服务器
开发者
开发者

▲图24-5　集中式的版本管理系统

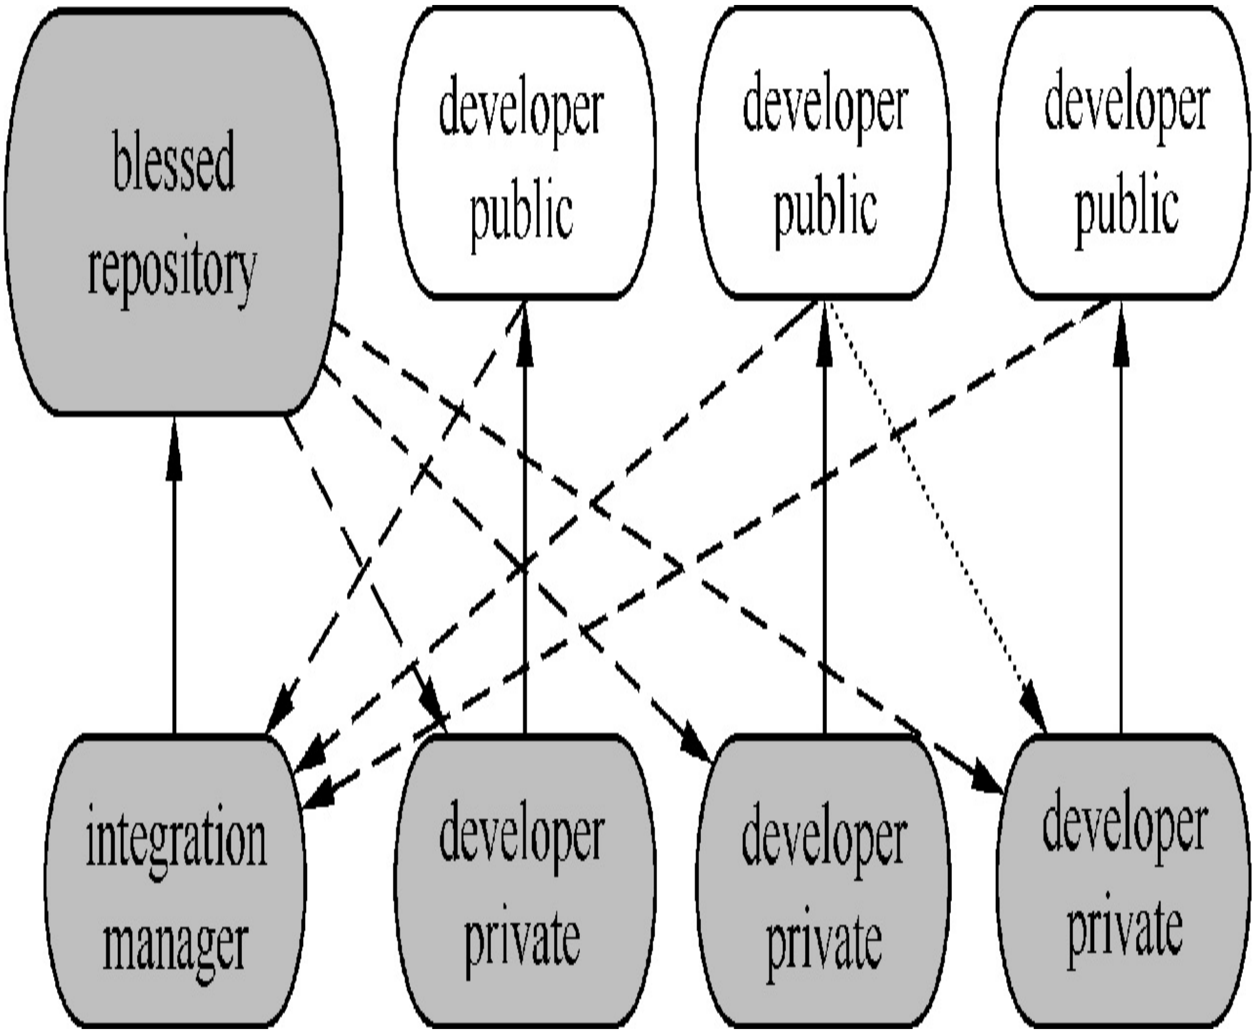

▲图24-6　集成管理员工作流
注：引用自http://git-scm.com/book。

其示意图如图24-6所示。

集成管理员模式的流程一般是：

- 管理员维护公共主仓库；
- 开发者将公共仓库的项目文件克隆到本地；
- 开发者根据需求进行项目研发；
- 开发者将项目修改推送到他们自己的公共仓库中；

- 开发者与管理员取得联系，要求管理员拉取修改文件；
- 管理员从开发者的公共仓库获取到最新修改；
- 管理员做本地合并并验证；
- 管理员将验证后的修改推送到主仓库中。

另一种方式称为“司令与副官工作流”（Dictator and Lieutenants Workflow）。顾名思义，这是一种多层级的工作方式。就好比一个军队中有司令、副官、军长、师长等管理员，权力逐层下放，分而治之，如图24-7所示。

具体流程是：

- 只有司令员才可以向公共主仓库推送修改；
- 普通开发者通过公共主仓库获取到项目文件；
- 普通开发者根据需求进行项目研发；
- 副官们将开发者的修改合并入他们的分支中；
- 司令员将副官们的分支合并入他的主分支中；
- 司令员将最终结果推送至公共主仓库中。

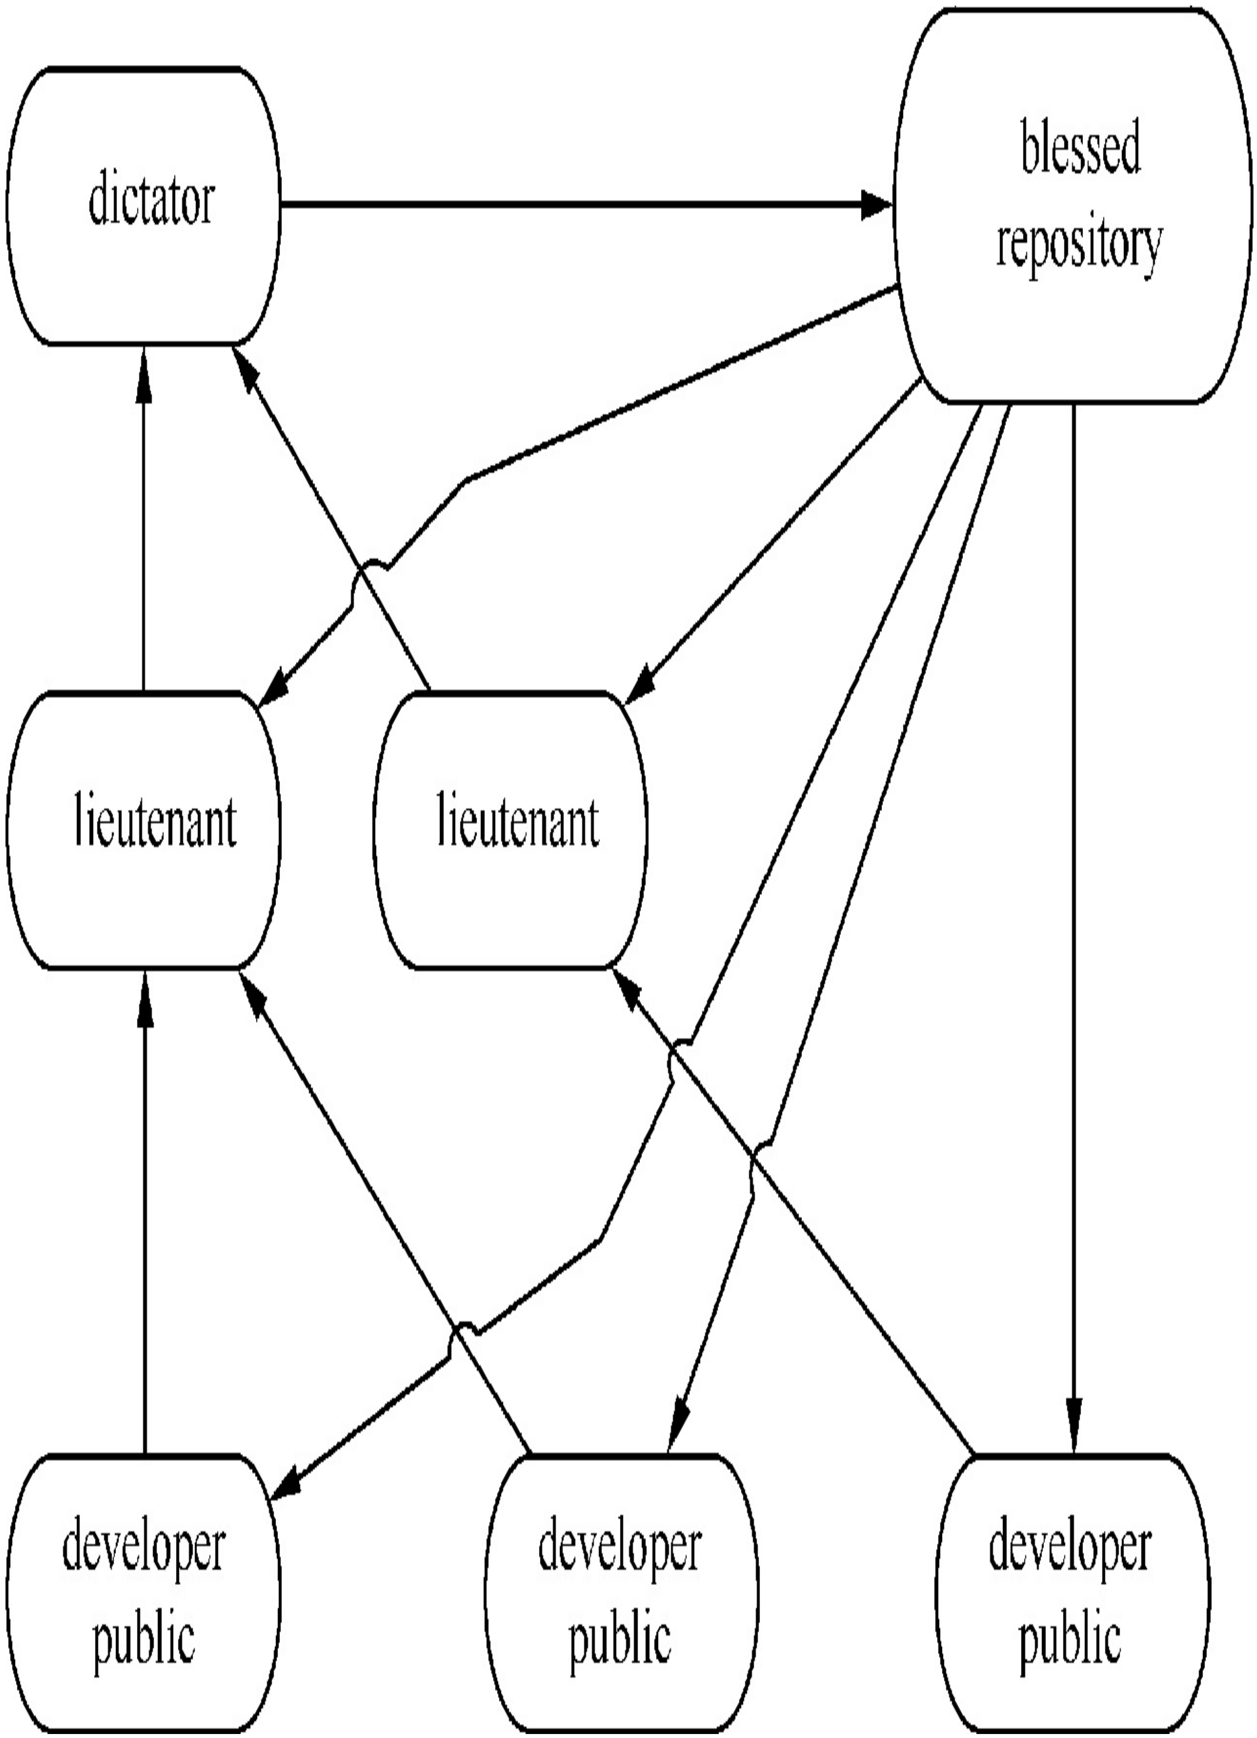
dictator
blessed repository
lieutenant
lieutenant
developer public
developer public
developer public

▲图24-7　司令与副官工作流

注：引用自http://git-scm.com/book。

这种形式的开发模型比前两种都要烦琐些，一般只会被应用于超大型项目的管理中。比如Linux内核的开发就采用了类似“司令与副官工作流”的方法。对于普通项目的研发，并不见得适用。

24.4.2　安全散列算法——SHA-1

在进入Git的分析前，读者还有一个基础知识需要补充，即SHA-1。

SHA（Secure Hash Algorithm）是由美国国家标准与技术研究院（National Institute of Standards and Technology）发布的一系列安全散列算法。其初始版本SHA-0于1993年诞生于美国国家安全局（National Security Agency）。但是第一个版本很快就因某些未曾公开的缺陷而被撤销，随后便被SHA-1取代。

SHA-1到目前为止都还被认为是安全可靠的。它可以从小于2^{64}位的信息中产生一串160位的摘要，因此通常被用于做数据的完整性校验。有兴趣的读者可以自行研究其算法原理，而学习Git只需要知道它的几个理论特性即可。

- 不可逆性

即我们没有办法从160位的摘要中还原出原始的数据。可以想象一下，如果我们可以从结果推导出初始值，甚至于近似值，那么基于这种散列的加密过程显然是没有任何意义的。

- 无碰撞性

碰撞的意思是两个不同的原始数据，产生同样的摘要结果。实际上，散列的碰撞是无法避免的。因为散列是从A->B的变换过程，而且B的大小只有160位——那么从数学概率的角度来说，一定存在碰撞的可能。所以，我们只能保证理论上是不会发生碰撞的。

- 摘要长度不变

不论原始数据多长（当然必须小于2^{64}位），其输出结果一定是160位。

在Git的设计中，SHA-1被广泛用于为某个对象（下一小节中有详细讲解）产生唯一的摘要值。因为这个值是唯一的，这样在理论上就可以把N个不同的对象彻底区分开来。这和我们一般情况下使用文件名来区别不同文件对象的想法有很大不同。Git里的对象文件名并不是真正项目中的文件名，而是这个对象内容的SHA-1散列值——而其真正的文件名存储在指向它的tree对象中。

我们在接下来的小节中具体分析这些对象。

24.4.3　4个重要对象

Git里有4个重要的对象（object）支撑起整个版本管理系统，即blob、tree、commit以及tag。刚开始接触Git的读者，可能对这些对象没有太多的概念。为了直观起见，我们仍然引用http://git-scm.com中提到的一个例子来进行具体说明。

这个例子针对的是这样一个项目：

```
./
|-- README
|-- LICENCE
|-- test.rb
```

经过commit动作后，几个对象间的关系如图24-8所示。

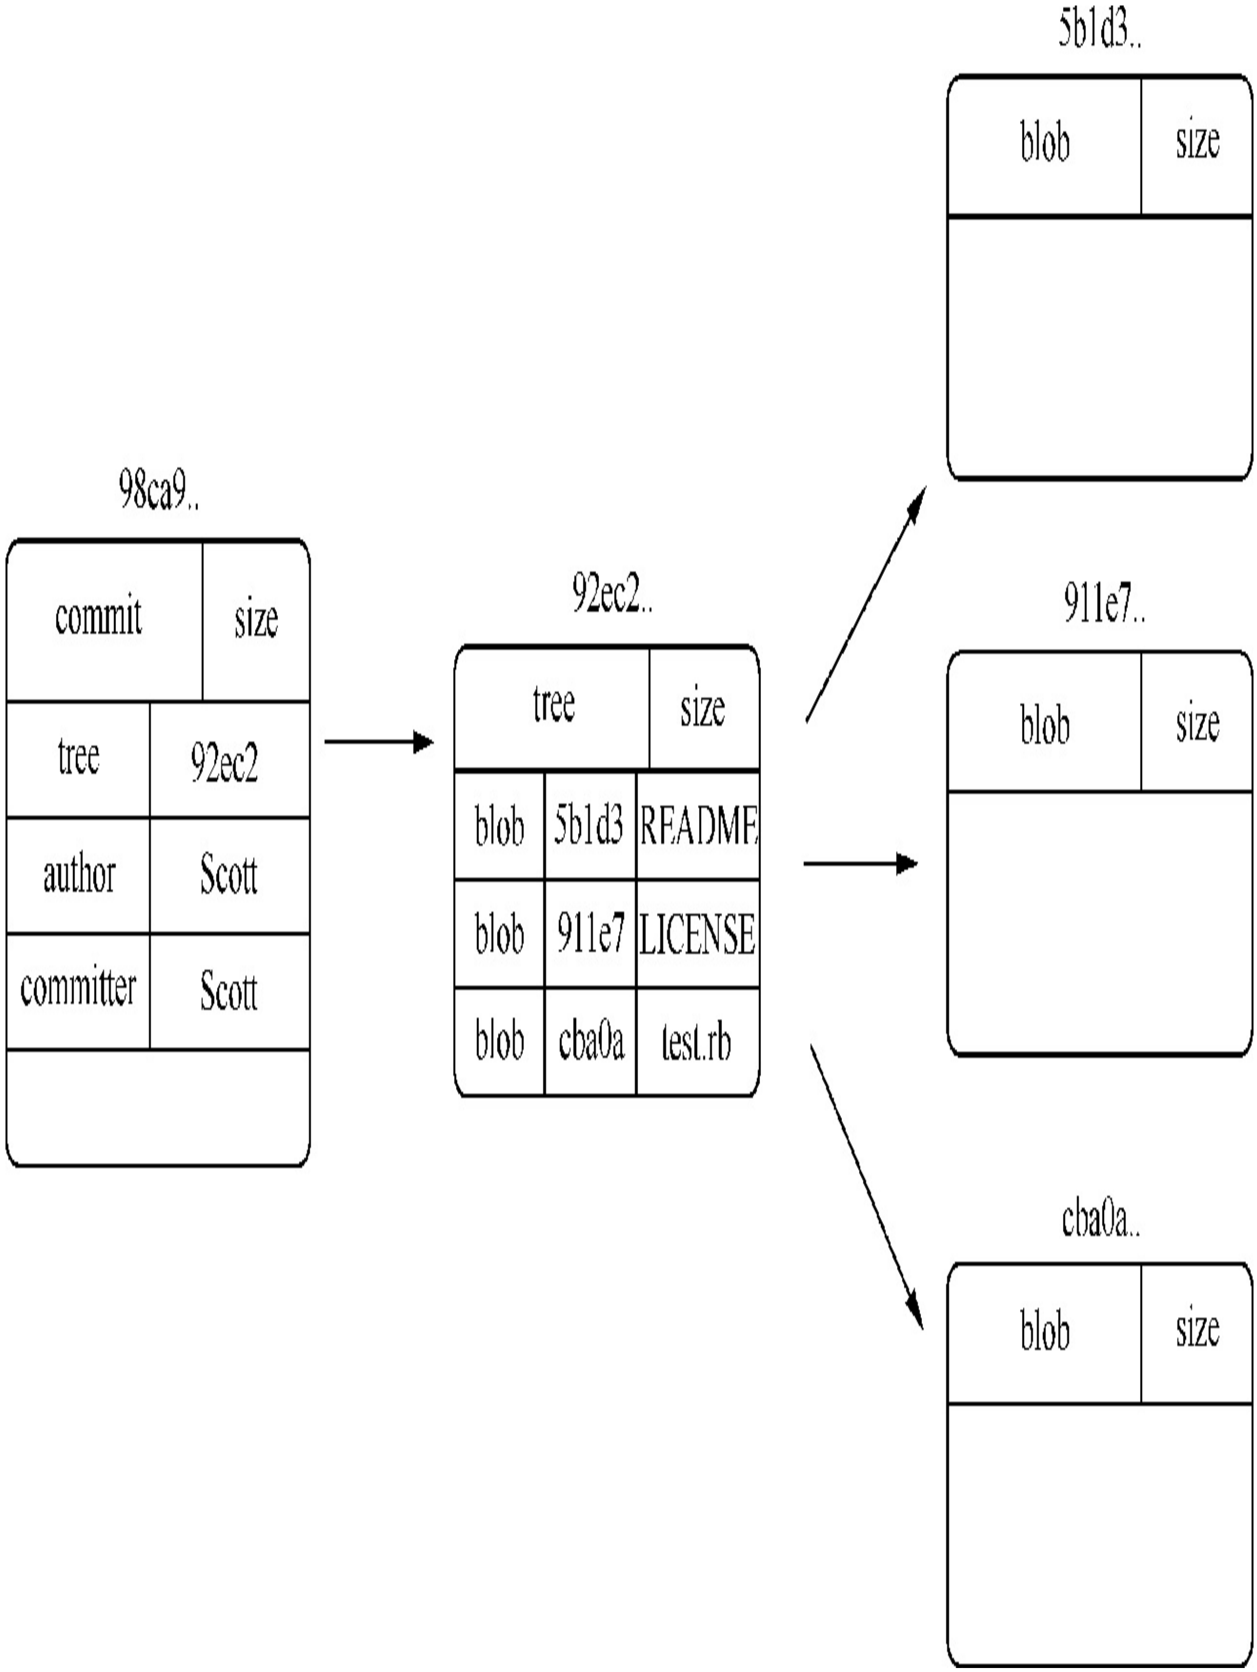
98ca9..
commit
size
tree
92ec2
author
Scott
committer
Scott
92ec2..
tree
size
blob
5b1d3
README
blob
911e7
LICENSE
blob
cba0a
test.rb
5b1d3..
blob
size
911e7..
blob
size
cba0a..
blob
size

▲图24-8　Git中的对象关系实例
（注：引用自http://git-scm.com。）

接下来将针对这个范例来分析各个对象。

1．Blob对象

在Git中，Blob对象用于存储文件内容。比如这个范例中有3个blob对象，分别用于储存README，LICENCE以及test.rb3个文件信息。

特别提示：Blob的文件名是如何获得的呢？

首先对项目文件的内容进行SHA-1运算以得到160位数据（以4位来表示一个字符。共有40个字符，范围是‘0’-‘9’、‘a’-‘f’）后，再将这160位数据值进行相关校验和运算，最后仍然得到160位数值。取前两个字符建立子目录，剩下的字符才作为blob文件名。因此如果细心观察，就会发现实际上blob文件名只有38个字符。

与很多其他的版本控制系统相比，Git对同一项目文件不同版本的内容存储有独到之处。

通常情况下，一个版本控制系统会对被修改的项目文件做版本差异运算，然后只保存这一差异值。比如项目文件A，上一个版本是v0.1。那么对A经过修改后再提交，它的新版本是v0.2。

我们通过运算得到两版本间的差异为Δ，即：

$$\Delta = diff(A^{v0.1}, A^{v0.2})$$

最终被保存到系统中的就是这个版本差异Δ。也就是说，如果想还原出文件A的v0.2版本内容，那么需要再次对两个版本文件进行差值运算，如图24-9所示。

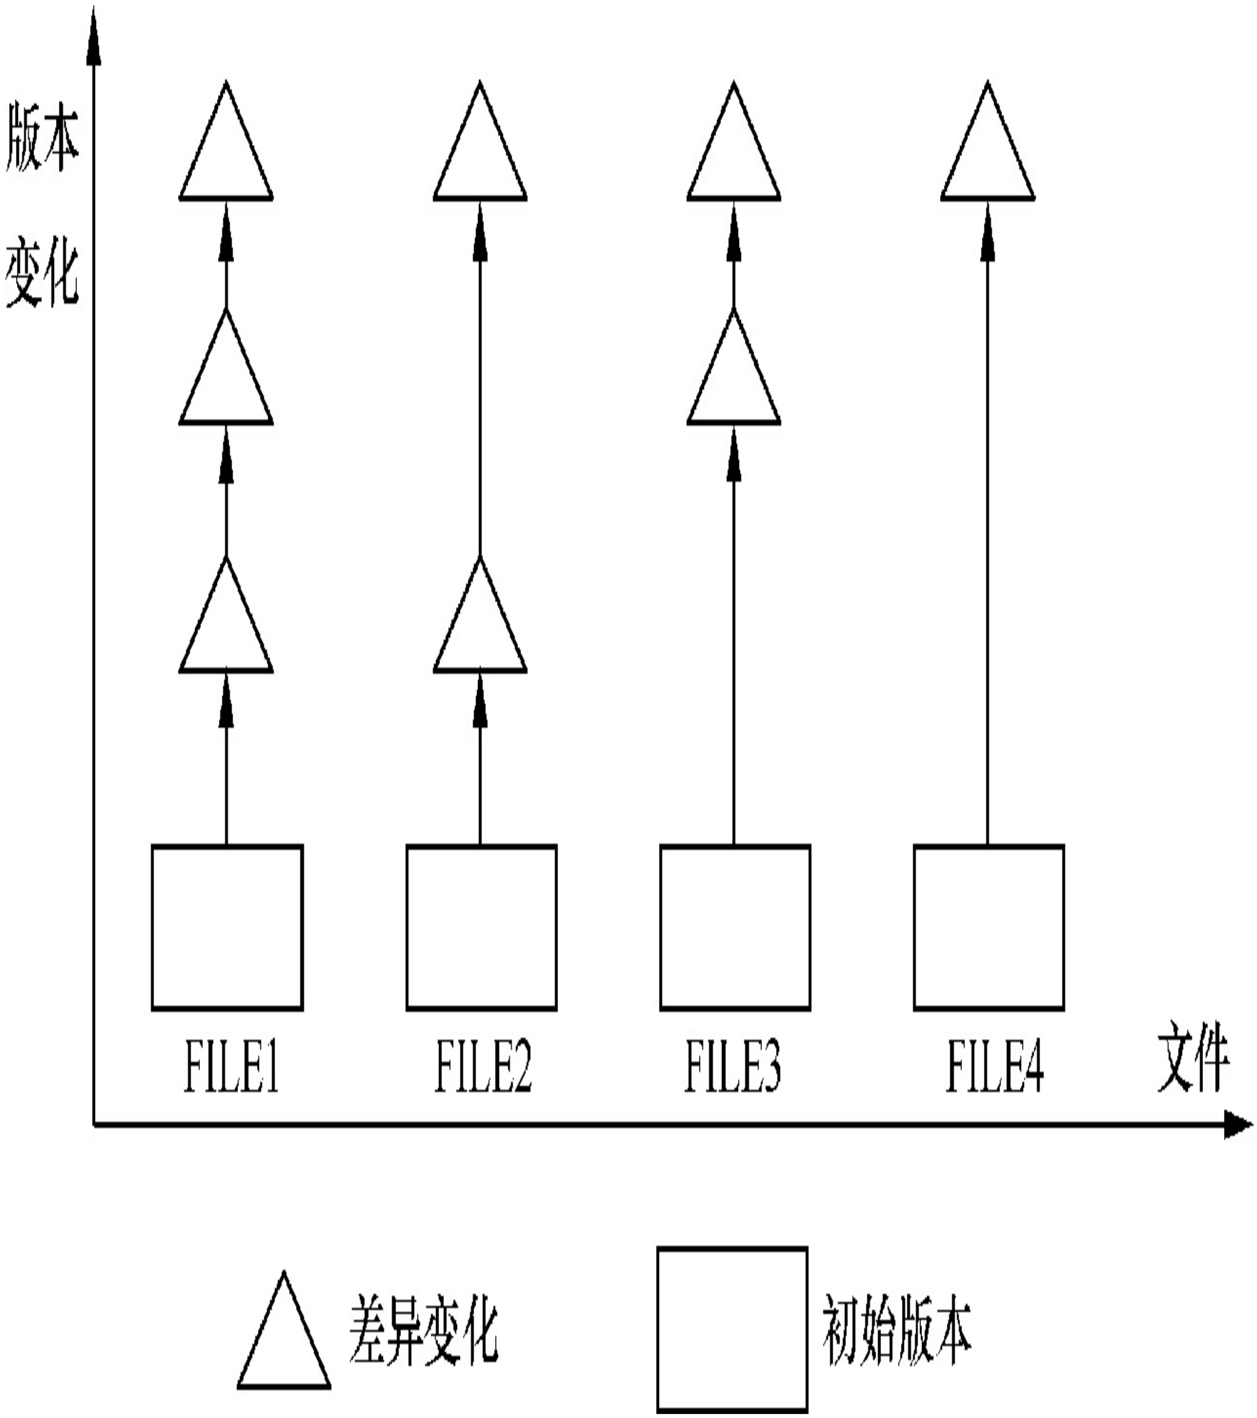

▲图24-9　普通VCS对不同版本文件的存储管理

Git的做法则有很大不同。它保存的并不是版本间的差异，而是整个修改后的文件内容（注意：其实不是单纯地保存内容，还需要进行SHA-1运算等操作），如图24-10所示。

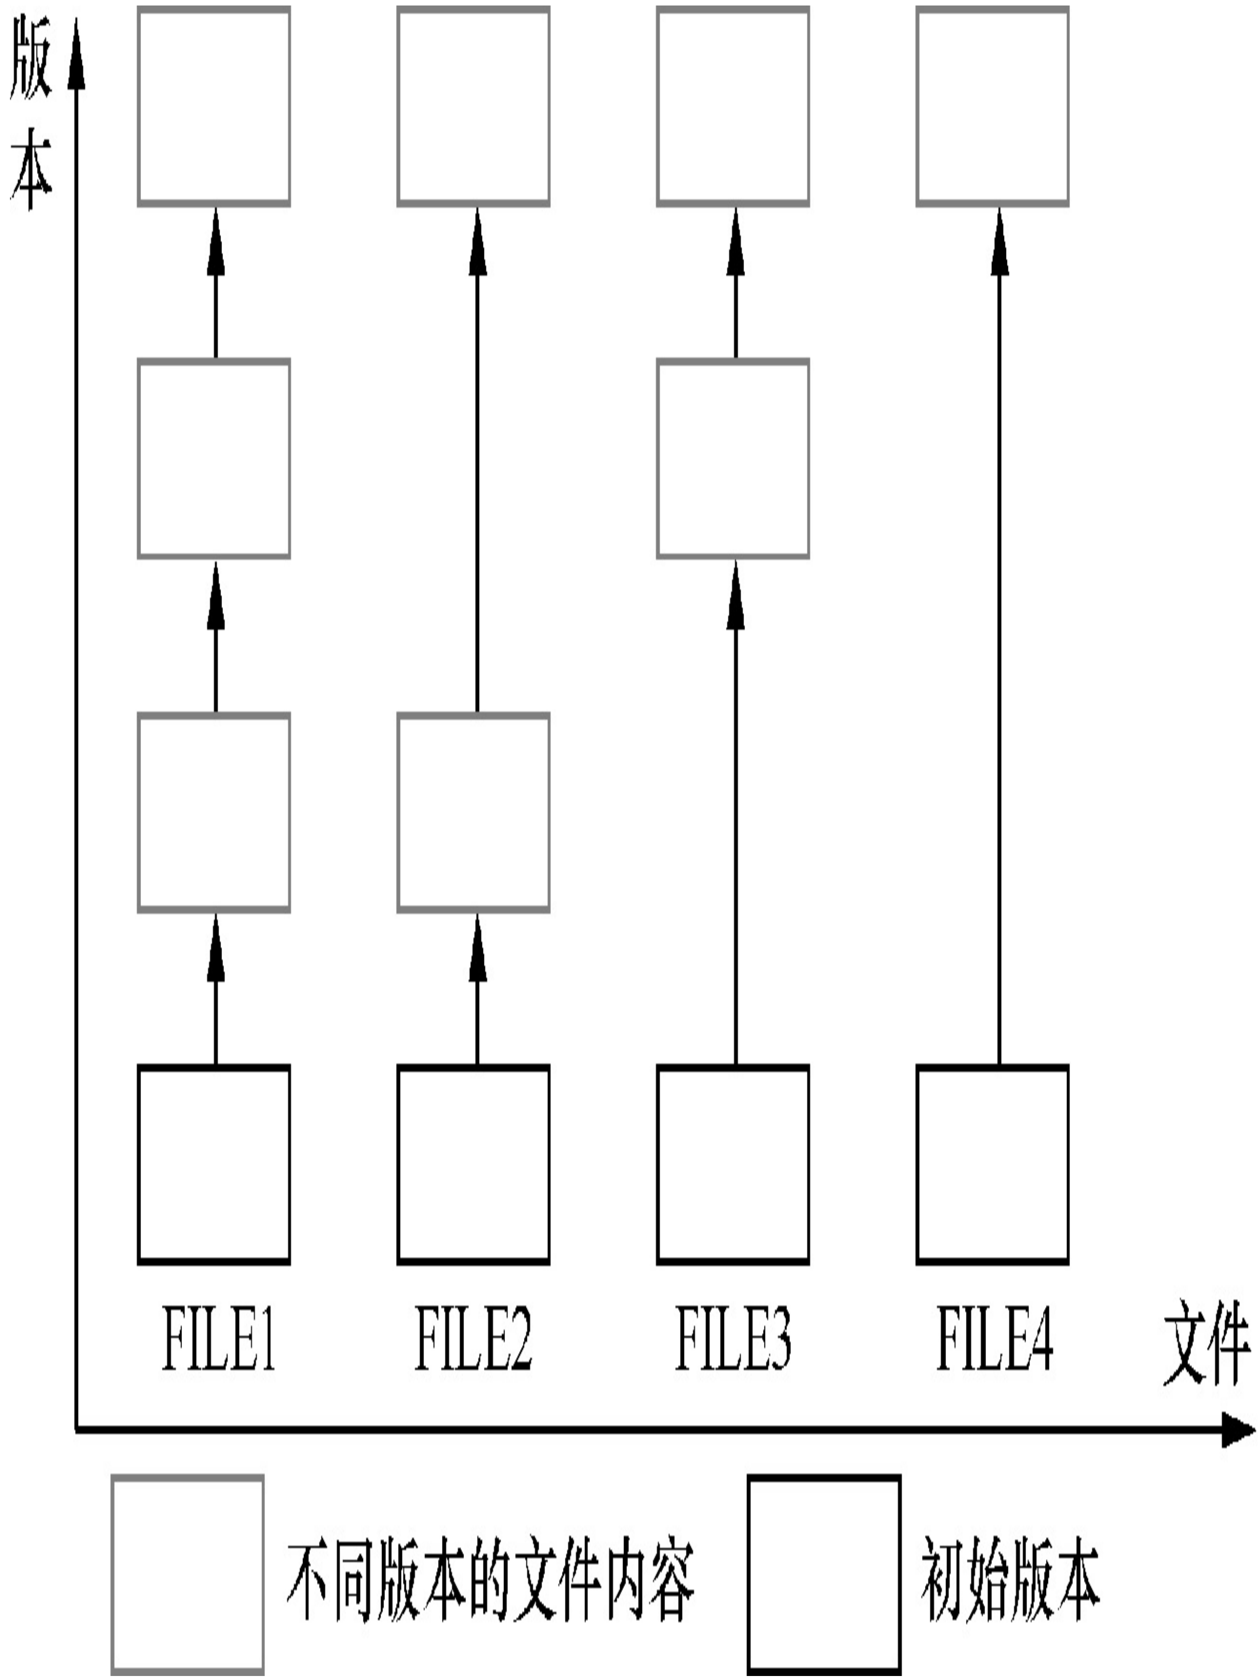

版本
FILE1
FILE2
FILE3
FILE4
文件
不同版本的文件内容
初始版本

▲图24-10　Git对不同版本文件的存储管理

显然，Git所采用的方式将增加系统对存储空间的要求。不过在当今的IT世界里，磁盘等存储设备容量越来越大，价格也越来越低，因此这种空间换时间的方法还是有其可取之处的。特别是由此带来的Git分支管理的快速与便捷，都是其他版本管理系统所无法比拟的。在接下来的小节中，我们还会谈到由此带来的Git在分支管理上的优势。

对于一个blob对象，记录它的全局标签是SHA-1串值。因此我们可以利用Git提供的工具来快速显示一个文件的内容。比如前面例子中的“utility.c”文件，其唯一标志值为“0acdfa4e476d0501f84b1cd9f48f90d088bfe247”，我们可以通过以下命令来得到文件内容。如下所示：

```
android@android-VirtualBox:~/Work/ThinkingInAndroid/GitTest$ git show 0acdfa4e47
6d0501f84b1cd9f48f90d088bfe247
#include "utility.h"

int getNumber()
{
        return 2;
}
```

另外，我们也可以使用图形化的工具来帮助理解各个版本间的关系和变化。比如，gitk就是一个很不错的分析工具。它的主界面如图24-11所示，有兴趣的读者可以自行参阅其官方资料。

2．Tree对象

前面所展示的例子中，tree对象的内容如图24-12所示。

可以看到，tree对象“92ec2…”包含了3个blob对象，即此项目的几个源文件。通过记录这3个文件的唯一标志值，tree可以非常方便地指向它们。Tree对象有点类似于目录的概念，因此它不仅可以指向blob，还可以指向tree对象，就好像一个目录下也可以有子目录一样。

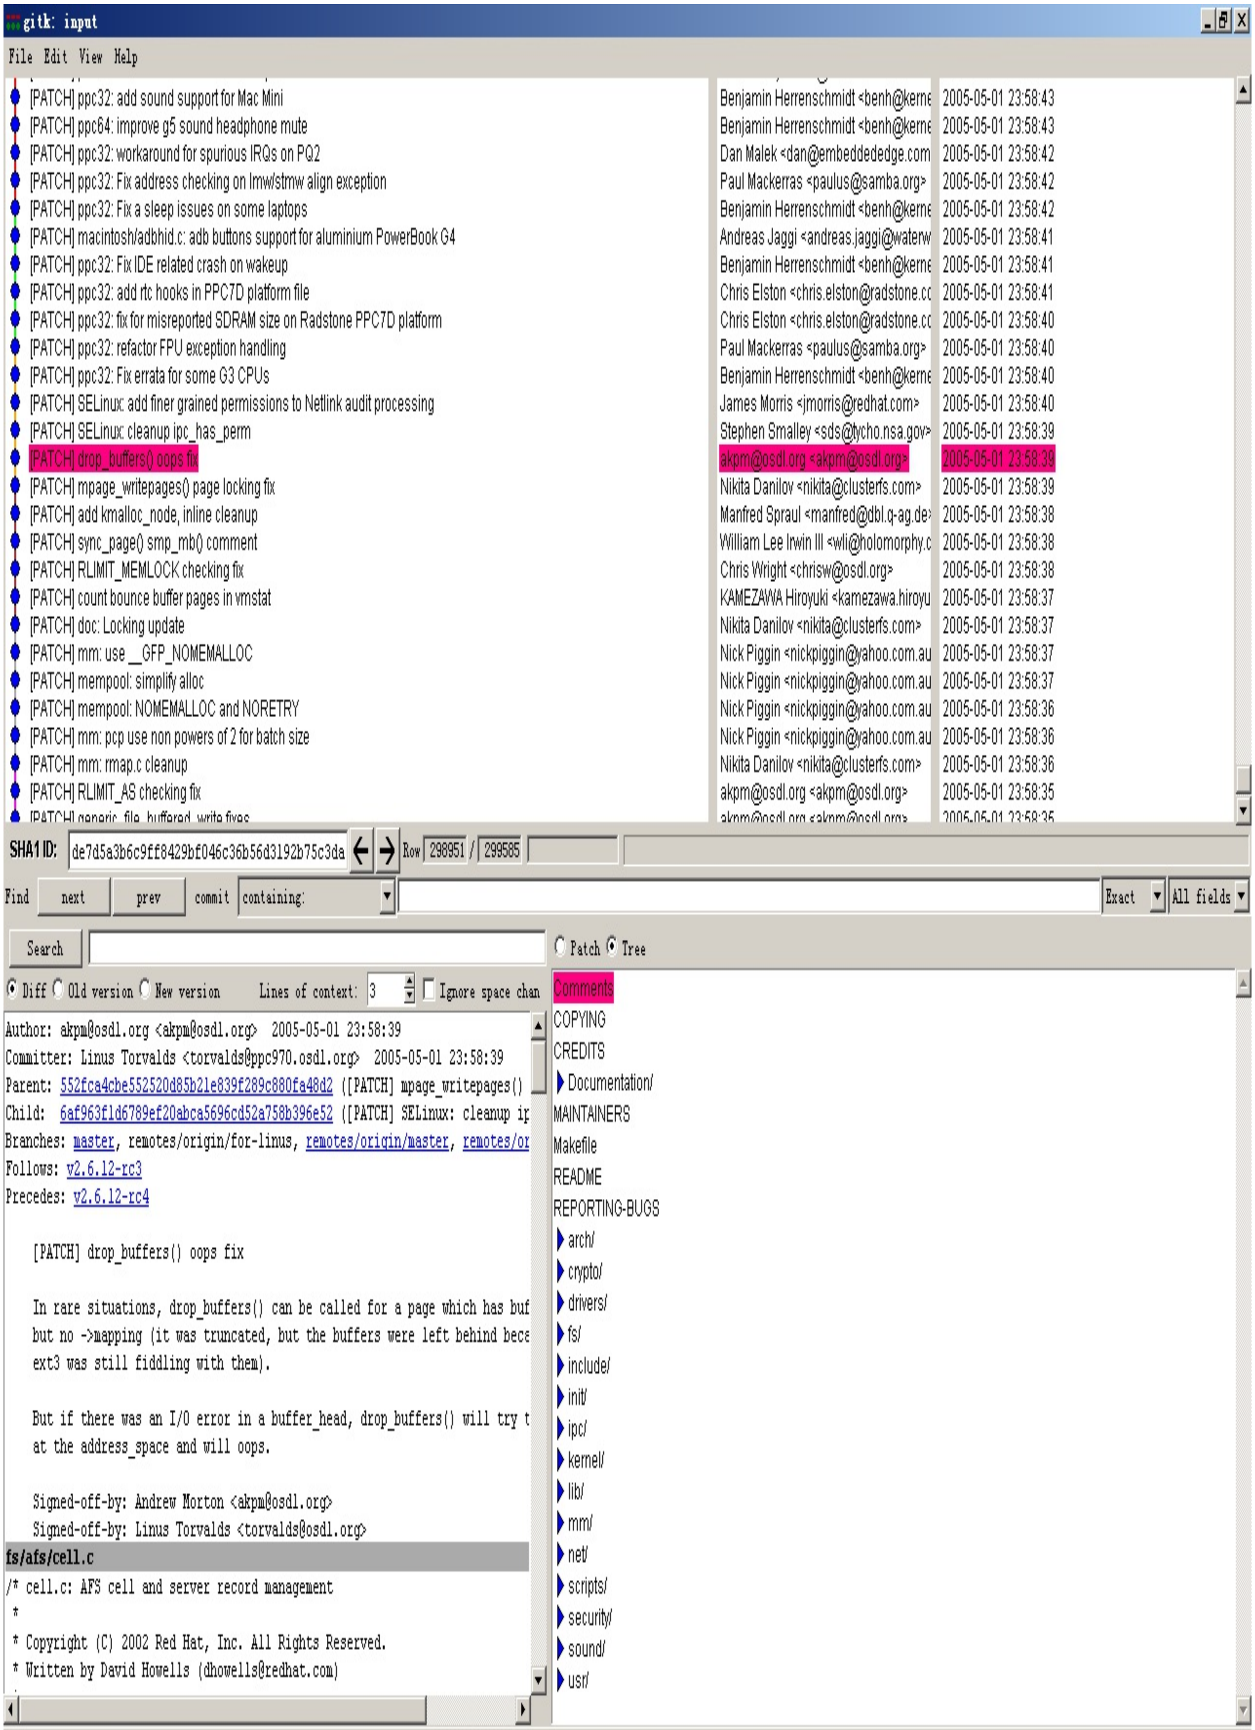
gitk: input
File Edit View Help
[PATCH] ppc32: add sound support for Mac Mini
[PATCH] ppc64: improve g5 sound headphone mute
[PATCH] ppc32: workaround for spurious IRQs on PQ2
[PATCH] ppc32: Fix address checking on lmw/stmw align exception
[PATCH] ppc32: Fix a sleep issues on some laptops
[PATCH] macintosh/adbhid.c: adb buttons support for aluminium PowerBook G4
[PATCH] ppc32: Fix IDE related crash on wakeup
[PATCH] ppc32: add rtc hooks in PPC7D platform file
[PATCH] ppc32: fix for misreported SDRAM size on Radstone PPC7D platform
[PATCH] ppc32: refactor FPU exception handling
[PATCH] ppc32: Fix errata for some G3 CPUs
[PATCH] SELinux: add finer grained permissions to Netlink audit processing
[PATCH] SELinux: cleanup ipc_has_perm
[PATCH] drop_buffers() oops fix
[PATCH] mpage_writepages() page locking fix
[PATCH] add kmalloc_node, inline cleanup
[PATCH] sync_page() smp_mb() comment
[PATCH] RLIMIT_MEMLOCK checking fix
[PATCH] count bounce buffer pages in vmstat
[PATCH] doc: Locking update
[PATCH] mm: use __GFP_NOMEMALLOC
[PATCH] mempool: simplify alloc
[PATCH] mempool: NOMEMALLOC and NORETRY
[PATCH] mm: pcp use non powers of 2 for batch size
[PATCH] mm: rmap.c cleanup
[PATCH] RLIMIT_AS checking fix
Benjamin Herrenschmidt <benh@kerne 2005-05-01 23:58:43
Benjamin Herrenschmidt <benh@kerne 2005-05-01 23:58:43
Dan Malek <dan@embeddededge.com 2005-05-01 23:58:42
Paul Mackerras <paulus@samba.org> 2005-05-01 23:58:42
Benjamin Herrenschmidt <benh@kerne 2005-05-01 23:58:42
Andreas Jaggi <andreas.jaggi@waterw 2005-05-01 23:58:41
Benjamin Herrenschmidt <benh@kerne 2005-05-01 23:58:41
Chris Elston <chris.elston@radstone.cc 2005-05-01 23:58:41
Chris Elston <chris.elston@radstone.cc 2005-05-01 23:58:40
Paul Mackerras <paulus@samba.org> 2005-05-01 23:58:40
Benjamin Herrenschmidt <benh@kerne 2005-05-01 23:58:40
James Morris <jmorris@redhat.com> 2005-05-01 23:58:40
Stephen Smalley <sds@tycho.nsa.gov> 2005-05-01 23:58:39
akpm@osdl.org <akpm@osdl.org> 2005-05-01 23:58:39
Nikita Danilov <nikita@clusterfs.com> 2005-05-01 23:58:39
Manfred Spraul <manfred@dbl.q-ag.de> 2005-05-01 23:58:38
William Lee Irwin III <wli@holomorphy.c 2005-05-01 23:58:38
Chris Wright <chrisw@osdl.org> 2005-05-01 23:58:38
KAMEZAWA Hiroyuki <kamezawa.hiroyu 2005-05-01 23:58:37
Nikita Danilov <nikita@clusterfs.com> 2005-05-01 23:58:37
Nick Piggin <nickpiggin@yahoo.com.au 2005-05-01 23:58:37
Nick Piggin <nickpiggin@yahoo.com.au 2005-05-01 23:58:37
Nick Piggin <nickpiggin@yahoo.com.au 2005-05-01 23:58:36
Nick Piggin <nickpiggin@yahoo.com.au 2005-05-01 23:58:36
Nikita Danilov <nikita@clusterfs.com> 2005-05-01 23:58:36
akpm@osdl.org <akpm@osdl.org> 2005-05-01 23:58:35
SHA1 ID: de7d5a3b6c9ff8429bf046c36b56d3192b75c3da
Row 298951 / 299585
Find next prev commit containing: Exact All fields
Search
Patch Tree
Diff Old version New version Lines of context: 3 Ignore space chan
Author: akpm@osdl.org <akpm@osdl.org> 2005-05-01 23:58:39
Committer: Linus Torvalds <torvalds@ppc970.osdl.org> 2005-05-01 23:58:39
Parent: 552fca4cbe552520d85b21e839f289c880fa48d2 ([PATCH] mpage_writepages()
Child: 6af963f1d6789ef20abca5696cd52a758b396e52 ([PATCH] SELinux: cleanup ip
Branches: master, remotes/origin/for-linus, remotes/origin/master, remotes/or
Follows: v2.6.12-rc3
Precedes: v2.6.12-rc4
[PATCH] drop_buffers() oops fix
In rare situations, drop_buffers() can be called for a page which has buf
but no ->mapping (it was truncated, but the buffers were left behind bec
ext3 was still fiddling with them).
But if there was an I/O error in a buffer_head, drop_buffers() will try t
at the address_space and will oops.
Signed-off-by: Andrew Morton <akpm@osdl.org>
Signed-off-by: Linus Torvalds <torvalds@osdl.org>
fs/afs/cell.c
/* cell.c: AFS cell and server record management
*
* Copyright (C) 2002 Red Hat, Inc. All Rights Reserved.
* Written by David Howells (dhowells@redhat.com)
Comments
COPYING
CREDITS
Documentation/
MAINTAINERS
Makefile
README
REPORTING-BUGS
arch/
crypto/
drivers/
fs/
include/
init/
ipc/
kernel/
lib/
mm/
net/
scripts/
security/
sound/
usr/

▲图24-11　gitk的一般用户界面

通过Git的如下命令，我们能获知一个对象的类型。

```
git cat-file -t <OBJECT>
```

例子如下所示：

```
android@android-VirtualBox:~/Work/ThinkingInAndroid/GitTest$ git cat-file -t 0ac
dfa4e476d0501f84b1cd9f48f90d088bfe247
blob
```

Tree对象将众多的blob和tree组织起来，形成一棵无环树结构，这是后面我们将提到的commit对象的基础。

另外，通过如下命令可以打印对象的内容：

```
git cat-file -p <OBJECT>
```

范例如下所示：

```
s@ubuntu:~/gittest$ git cat-file -p fee5cc
tree e625d6b666b55cce10185fb2cc0ebc919f91787b
author lxs <lxs@xxx.com> 1471705562 -0700
committer lxs <lxs@xxx.com> 1471705562 -0700

This is the first commit
```

3．Commit对象

Commit对象，从名称就可以猜到它是记录每次提交相关信息的一个对象。我们仍然结合前面小节的例子来为读者进行讲解，如图24-13所示。

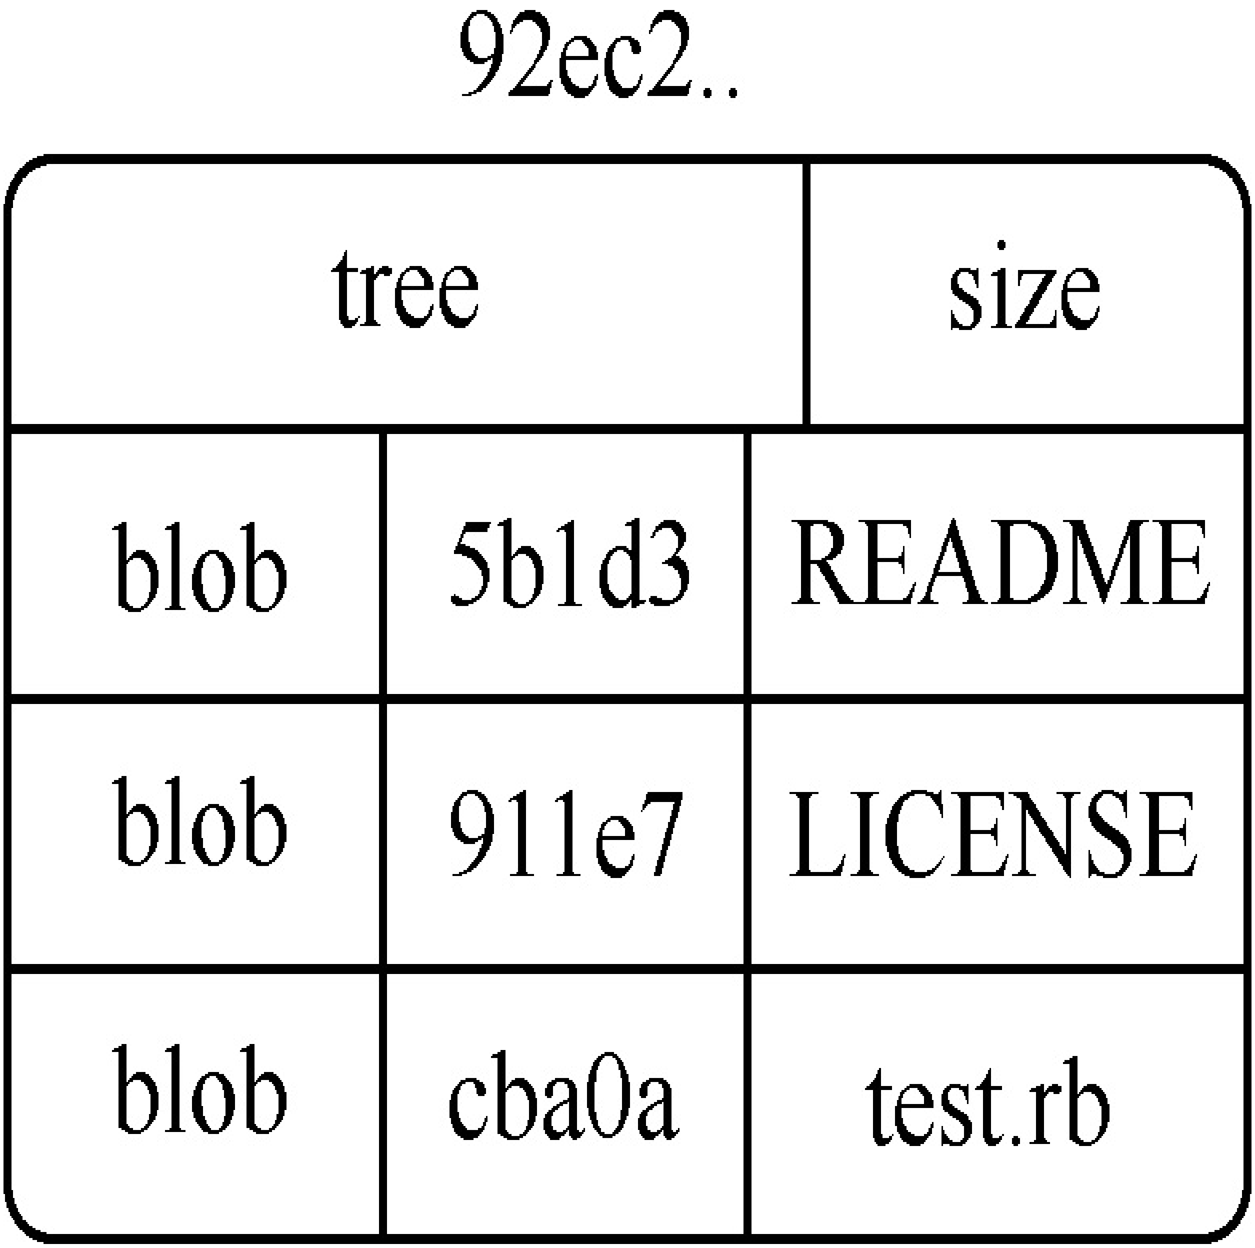

▲图24-12　tree对象的内容

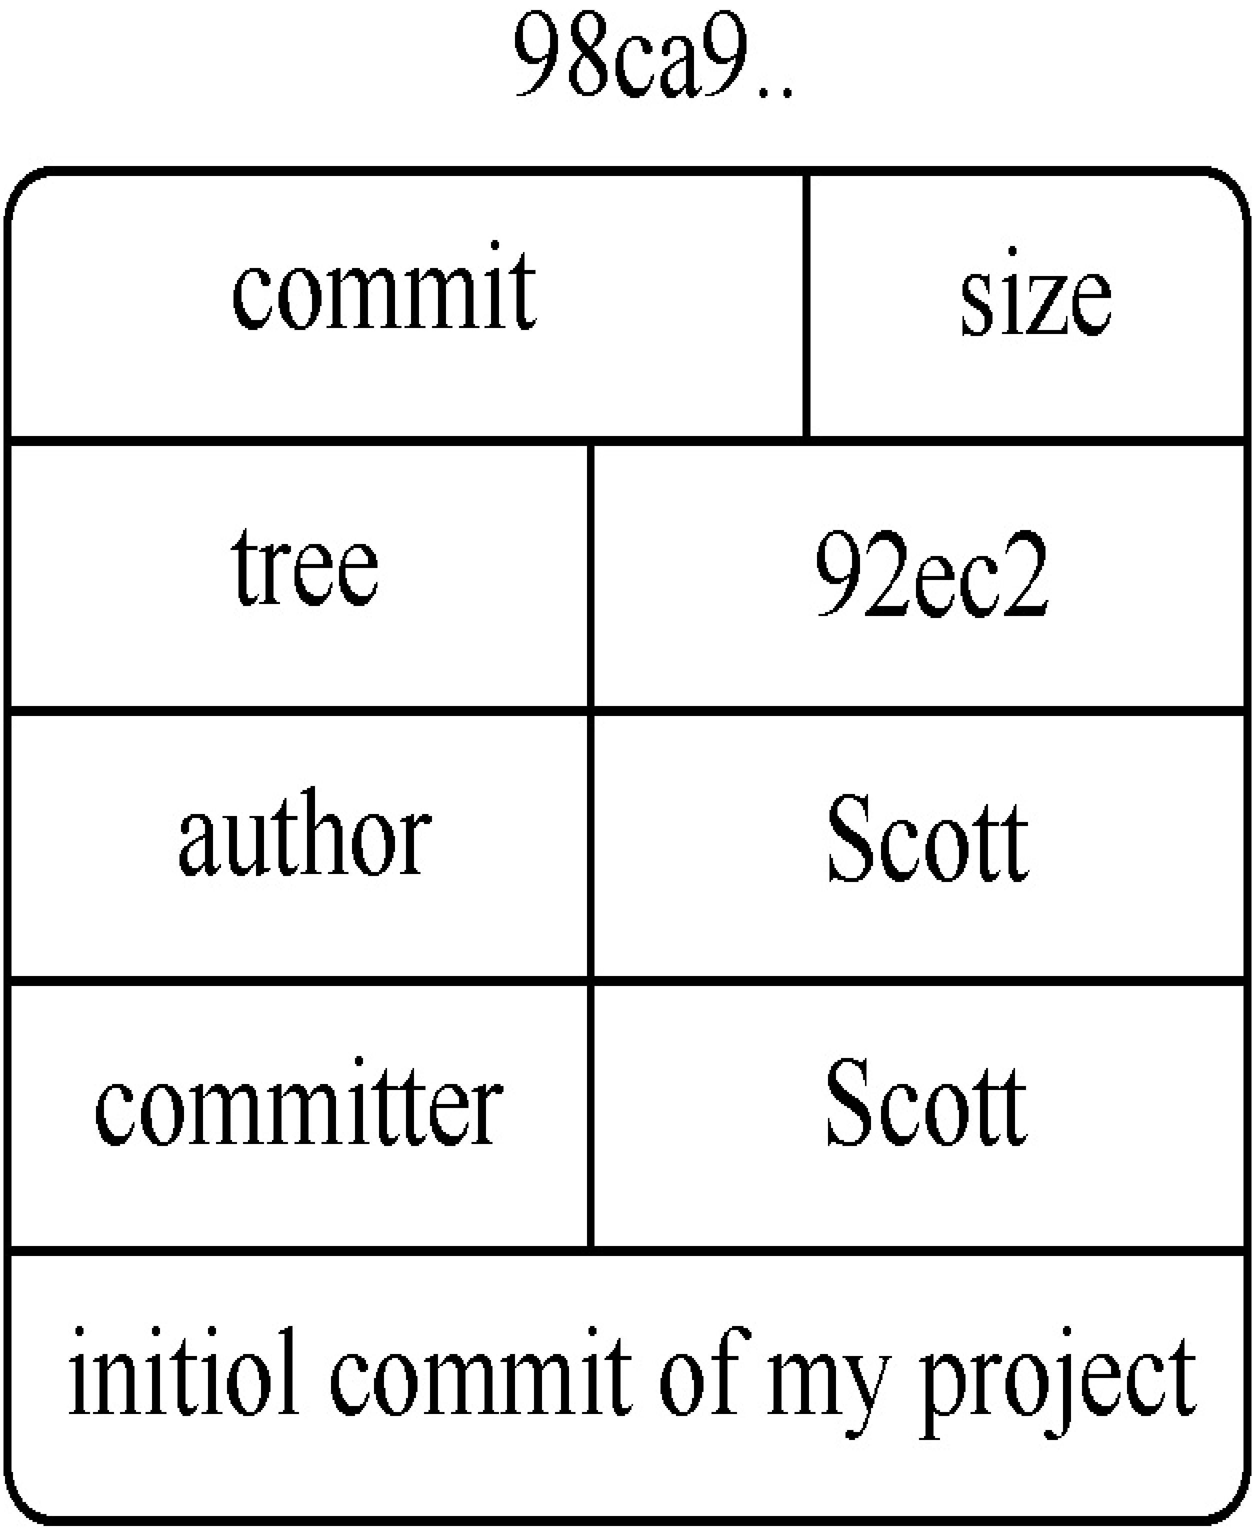

▲图21-13　实例

它包括如下信息：

- Tree对象。这是本次提交所涉及的所有文件的集合。和前面看到的情况一样，commit指向tree对象的唯一标志符。
- 作者（author）。本次修改者的名字。
- 提交者（commiter）。本次提交者的名字，它可以和作者不同。比如在管理员模式中，开发者做了修改工作，但管理员才是最终的提交者。
- 备注（comment）。对于本次提交的说明备注，这将有利于我们追踪每次版本的内容变化。

对于非初次提交，它可能还会有“parent”说明——这个栏位将指向上一次的提交对象。比如图24-14展示的是3次提交后的commit对象关系。

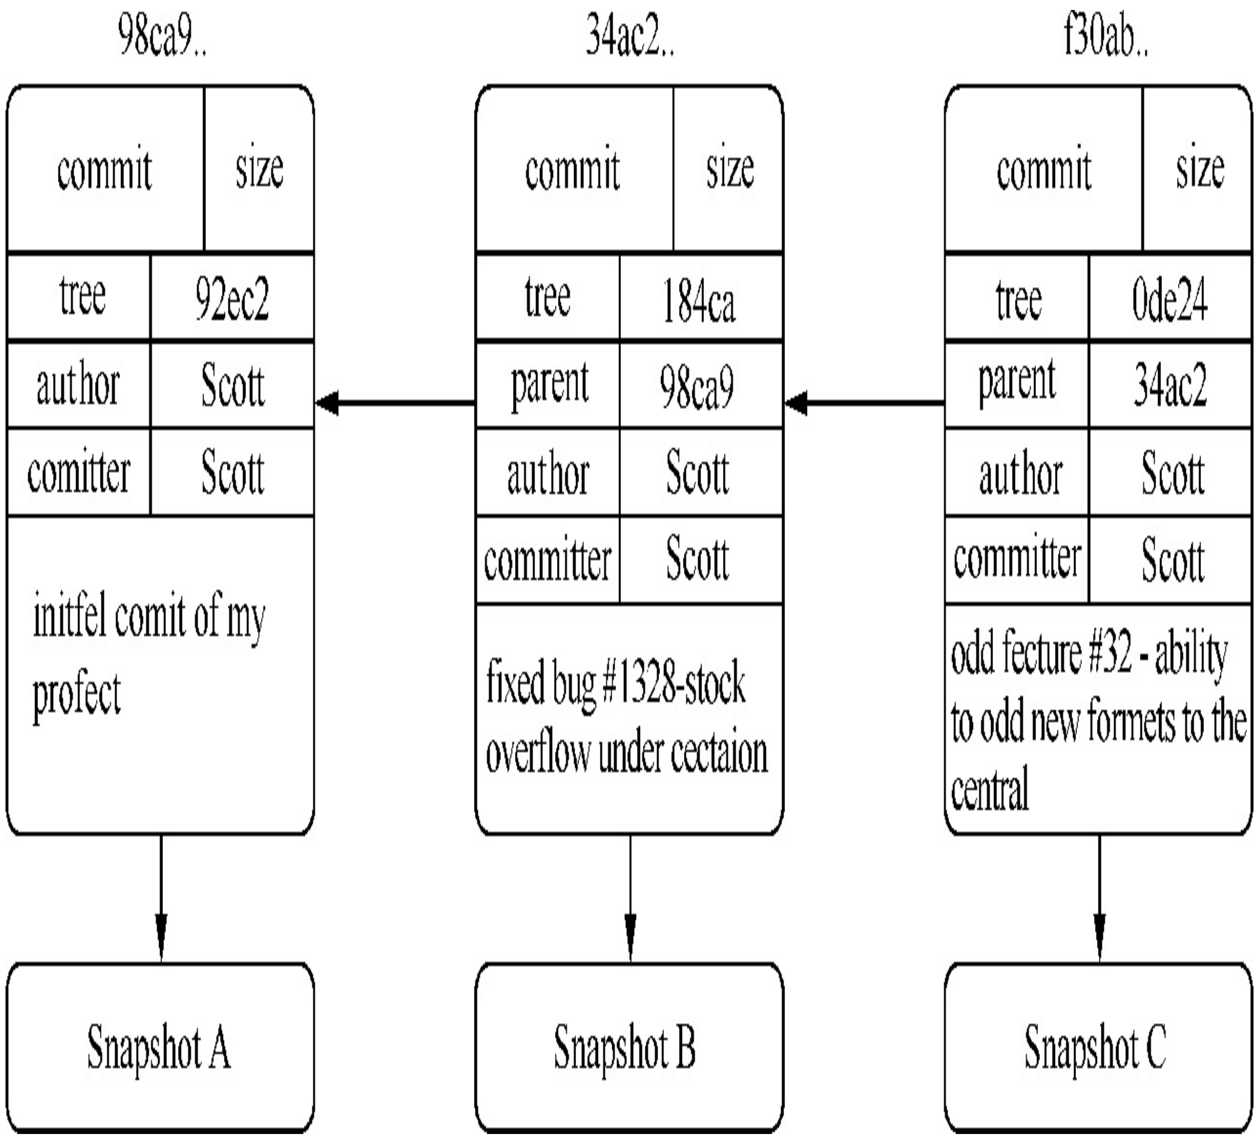

▲图24-14　多次提交后的commit对象关系图
（注：引用自http://git-scm.com/book。）

由于“parent”的存在，我们可以很方便地追溯到任意版本的历史记录，并推算出每个版本发生了哪些修改。而这种推算的性价比很高，因为我们实际只是创建了一个个的commit对象，占据了非常有限的存储空间。这种链式结构的commit关系图也是Git中分支管理的基础之一，它为分支管理的快速性提供了本质保障。

我们可以通过以下命令来查看一个commit对象：

```
gitshow –s --pretty=raw <OBJECT>
```

结果显示如下：

```
android@android-VirtualBox:~/Work/ThinkingInAndroid/GitTest$ git show -s --pretty=raw d889964aaafcef3ce56fd31007c70174cb62e79d
commit d889964aaafcef3ce56fd31007c70174cb62e79d
tree 5d8fcf8d3895496eb70febaaa50a234040f1ec7b
parent 0df9ec62189dc8dd63e8ae655673efc98396a2c8
author Xuesen Lin <android@android-VirtualBox.(none)> 1340938774 +0800
committer Xuesen Lin <android@android-VirtualBox.(none)> 1340938774 +0800

    second commit
```

值得一提的是，通过每次commit所指向的tree，事实上都能得到整个项目的全部文件的最新状态。这样做的好处是非常明显的，即不用遍历提交树就可以还原出工程状态。如下是我们在Android N版本中针对art虚拟机子项目执行“git cat-file -p [最后一次commit所对应的tree对象]”命令所得到的结果范例：

```
100644 blob c4cf98b37c0e25fb0626d53dec10b157b76d662e    .gitignore
100644 blob 3467f1d0623c219d00b40c4459b51b4196047c82    Android.mk
100644 blob 341df784001c0c231c38a98068b930434bf5e235    CleanSpec.mk
100644 blob e69de29bb2d1d6434b8b29ae775ad8c2e48c5391    MODULE_LICENSE_APACHE2
100644 blob d27f6a671456e9306054955acb1fba006c9b1ba0    NOTICE
040000 tree 8e7bef719166e764d0dc56db899770fb43285f41    build
040000 tree b5107b82e7a74225d4d2dc153ad0a29998d47050    cmdline
040000 tree 81d9b8747e46dd9090cde5ea661ecbee3efd3e91    compiler
040000 tree f1853f69a2ea0a781c9d47c16e52841e04a2ee45    dalvikvm
040000 tree 840eb7e7f4044b65d5cb58c68dafa682ad1a2c0a    dex2oat
040000 tree 95f2df3ea034dc874d42b71936182695ff571dd9    disassembler
040000 tree 193f1eb445c0be22e7640ae33b5cf73880beb603    imgdiag
040000 tree 06b8a2f10a772a0cccc816bf27d0460858de280e    oatdump
040000 tree 5b58a7bd1c94c5ee7bd85e6a4616ae01da9a3f3b    patchoat
040000 tree 8235cca340a59548587fbd5fb9c4044df64dc0ec    runtime
040000 tree 92b7e5463186a11354b6b84ab43a009bb999ecc2    sigchainlib
040000 tree 7224495c1c89b3e7bbdb635733d9cfc2b62f0454    test
040000 tree a44699f198fece860db285541e5f8f559c97becd    tools
```

4．Tag对象

标签对象为冗长的SHA-1字符串提供了便捷的记忆方法。就好比我们一般不会去记住某个网站的IP地址一样——因为只要知道网站域名，自然有DNS去做解析工作。

一个tag对象通常包括如下信息。

- Object（对象名）。这是由SHA-1计算出来的。
- Type（类型）。对象的类型。
- Tag（tag名称）。我们创建tag对象时提供的名称。
- Tagger（tag创建者）。创建本条tag对象的人。
- Message（信息）。描述这条tag的相关信息。
- Signature（签名）。如果创建tag时选择了签名，这条标签就附有签名信息。

创建、列出、删除和验证一条tag可以用如下命令。

```
git tag [-a | -s | -u <key-id>] [-f] [-m <msg> | -F <file>]
<tagname> [<commit> | <object>]
git tag -d <tagname>...
git tag [-n[<num>]] -l [--contains <commit>] [--points-at <object
[--column[=<options>] | --no-column] [<pattern>...]
[<pattern>...]
git tag -v <tagname>...
```

读者可以通过git －help命令来获取详情。

事实上，对tag的操作会体现在.git管理目录下的refs/tags中。每个tag对象会形成一个独立的文件，这样可以方便管理、查找和引用。

24.4.4　三个区域

在前面小节中，我们提到过Git中的所有文件都有4种状态。那么，这几种不同状态下的文件都分别是如何存储的呢？

在Git的管理中，总共维护了3个特殊区域来做存储工作。它们分别是：工作目录（Working Directory）、暂存区（Staging area）以及仓库（Repository）。

其关系如图24-15所示。

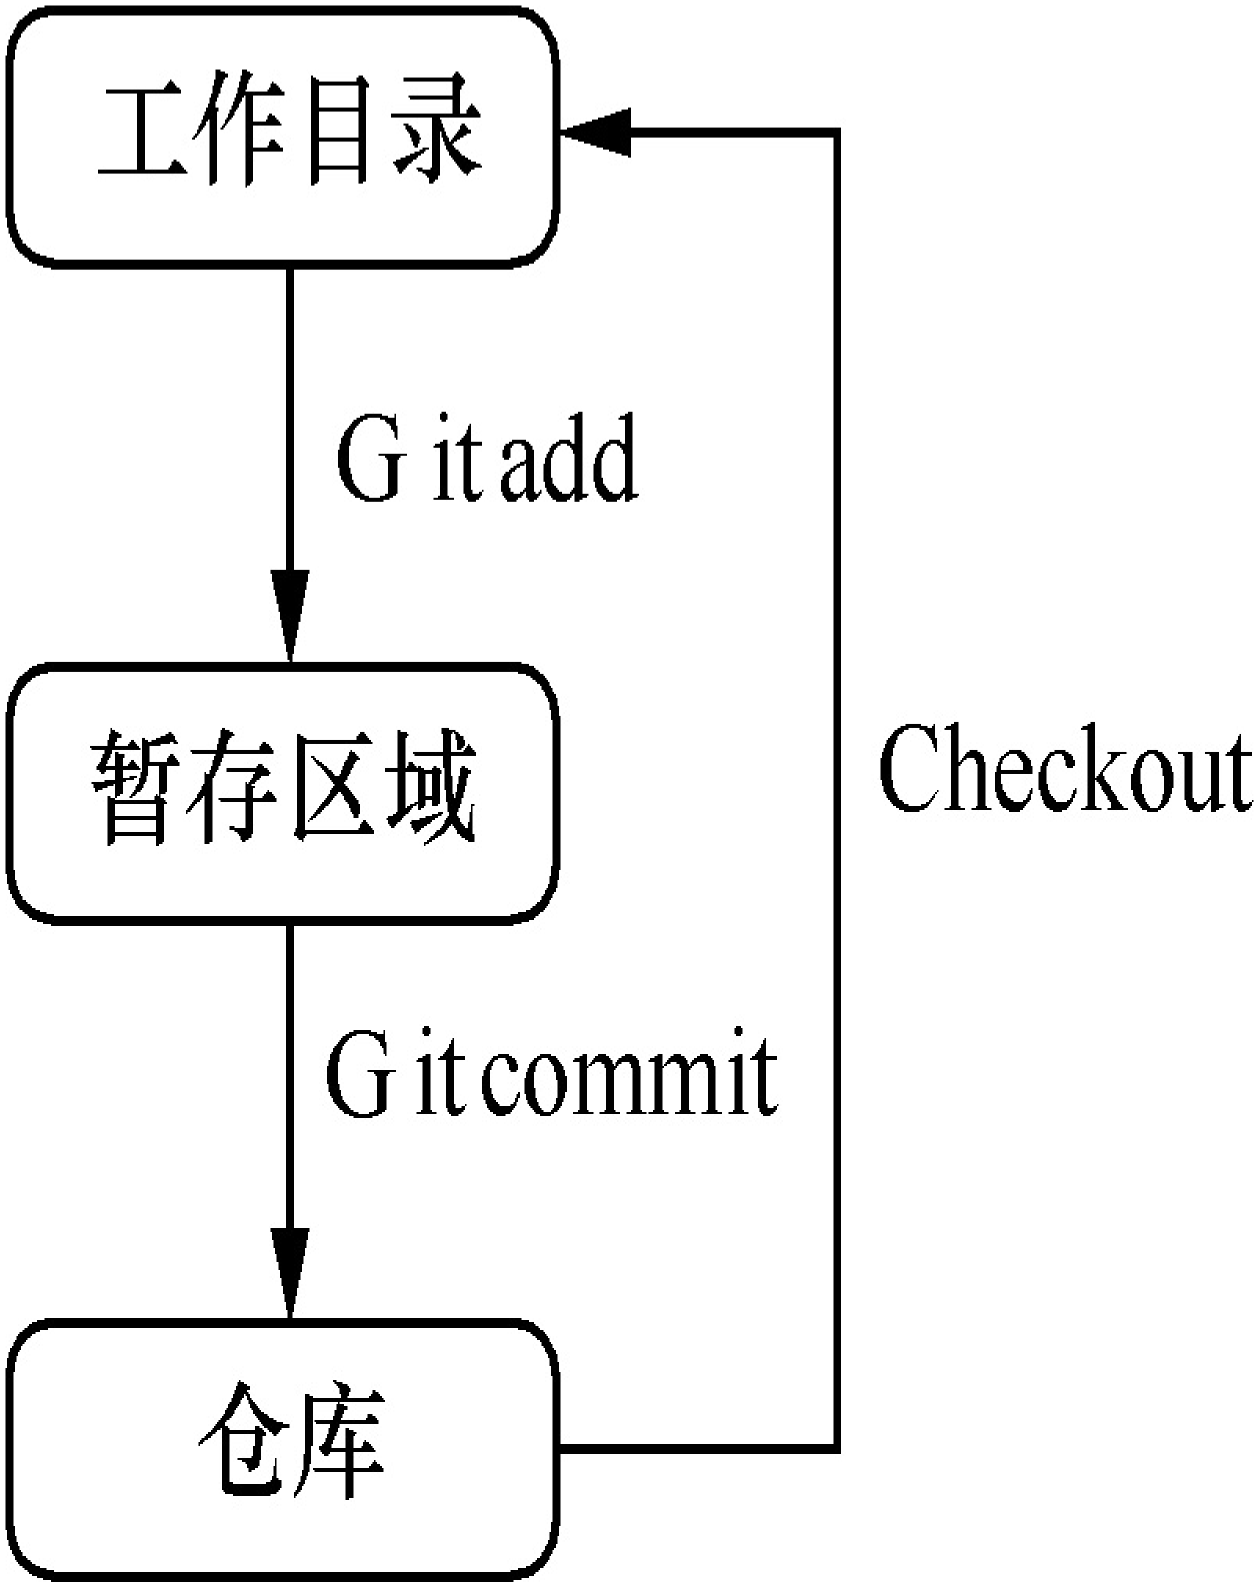

▲图24-15　Git中3个区域的概念

要正确理解这3个区域，可以先看看.git路径中的各管理文件和目录结构。官方文档并没有严格给出这3个区域的划分。因此从物理存储的角度来看，它们并非我们设想的3个独立的存储区域。针对Git的管理特点，可以这样理解它们的关系：

- 工作目录是项目文件所在的地方。一般情况下，它与.git目录是同级的。这里存放着开发者可以直接修改的众多项目文件，因此称之为工作目录。
- 暂存区域（Staging Area）其实是一个文件。对照Git的实现思想，暂存区域应当是.git目录下的index文件。这里记录着下一次需要提交的文件信息。开发者可以通过git add将新的文件或者已修改的文件加入这一区域中。对于那些未staged的项目文件，即便已经修改，也不会在下一次的提交中被更新到仓库中。因为有中间的暂存区域，开发者可以决定哪些文件是需要被提交到仓库中的、哪些则是没有必要的；而且如果发现有问题，也能很方便地撤销操作。
- 仓库（Repository）。这通常是指本地仓库，即.git/objects目录下的各对象文件。这里存储了所有版本项目文件的内容。对于一个大型项目来说，这些文件的数量可以轻易达到百万以上的级别，因此需要压缩和打包手段。如果你用git clone从远程仓库创建过项目，应该会发现克隆下来的objects目录下没有任何对象存在，而在/info和/pack目录下则有几个比较大的文件。这就是Git对松散对象实行的打包管理。

我们可以通过以下命令来做到这点：

```
git gc [--aggressive] [--auto] [--quiet] [--prune=<date> | --no-p
```

比如对于一个在本地创建的Git项目，经过多次操作后，objects目录下的文件情况如下所示。

▸ info	0 items	folder
▾ pack	0 items	folder
(Empty)		
▸ b2	1 item	folder
▸ 0a	1 item	folder
▸ 9d	1 item	folder
▸ 32	1 item	folder
▸ 45	1 item	folder
▸ a4	1 item	folder
▸ a8	1 item	folder
▸ e6	1 item	folder
▸ 87	1 item	folder
▸ 97	1 item	folder
▸ 0d	1 item	folder

可以清楚地看到，/info和/pack在起始时是空的，不包含任何对象。我们接下来执行gc命令，如下所示。

```
android@android-VirtualBox:~/Work/ThinkingInAndroid/GitTest$ git gc
Counting objects: 13, done.
Compressing objects: 100% (11/11), done.
Writing objects: 100% (13/13), done.
Total 13 (delta 0), reused 0 (delta 0)
```

之后可以得到新的结果如下所示。

▾ info	1 item	folder
packs	54 bytes	plain text document
▾ pack	2 items	folder
pack-52df365175736ca94cea2efa0e43802e6f32e386.idx	1.4 KB	unknown
pack-52df365175736ca94cea2efa0e43802e6f32e386.pack	1.8 KB	Pack200 Java archive
▸ e6	1 item	folder
▸ f5	1 item	folder

此时松散的object对象已经得到最大程度的打包和压缩处理，取而代之的是几个新文件。这种打包方式对于我们节省存储空间、提高处理效率以及推送文件到远程仓库，都是大有帮助的。

24.4.5　分支的概念与实例

分支（branch）管理是Git的一大特色——它所提供的快速与便捷的分支操作是开发者选择Git的主要原因之一。

1．什么是分支

如果查阅Git资料，就会发现分支这个词被频繁地提及。那么，什么是分支呢？从字面来理解，它应该是类似于江河分流的概念，即从主干上分叉开来而形成的小体系（在水文学中，支流是指汇入另一主干水体的河流，而分流则是相反的）。人们为了防止某些水系的规模太大造成洪水，或者为了农业，经常会进行人工分流的动作。

在版本控制系统中，branch代表了这一代码分支的源头是主干（master）；而且在初始状态时，它和主干的内容是一模一样的。而后随着开发的推进，分支逐渐有了自己独立的进度空间，和主体间便互不干扰了——直到另一时刻，基于项目的需求，我们可以再将这一分支合并入主干。创建分支的一个常见情景是：为项目开发一个新的功能（feature）。因为每一个新的功能开发都有一段或长或短的稳定期，直接在主枝上操作难免会影响到整个项目的稳定性，在这种情况下我们会选择创建一个分支来承载新功能的开发。

对于市面上的很多版本控制系统，新建分支意味着整个项目工程的复制——而这通常是烦琐而耗时的。Git基于自身的特点，提出了另一种高效的实现方式。

简而言之，就是：

Git中的分支，其实只是一个指针。

虽然实际过程会稍微复杂一些，但上面这句话却是Git分支的核心理念，因此请读者务必牢牢记住。后面我们再针对具体实例来慢慢解释这种说法的缘由。

2．Git中的分支指针

前面小节我们曾用简图描述过一个简单项目执行了3次提交后的commit对象关系。除了图中所示的链接外，其实还有一个分支指针没有标注出来。我们对简图做了修改，如图24-16所示。

我们说分支是一个指针，更进一步讲，它是指向某个commit对象的指针；而且在默认情况下，项目处于master开发分支中。因此从图中可以看到，分支指向了“f30ab…”这个commit对象。分支是一个动态变化的指针，每次提交后都会指向当前分支的最后一个commit（注意是针对当前分支的提交，其他分支的commit动作不会受影响）对象。

比如在3次提交后又有新的提交，那么指针就会变成如图24-17所示。

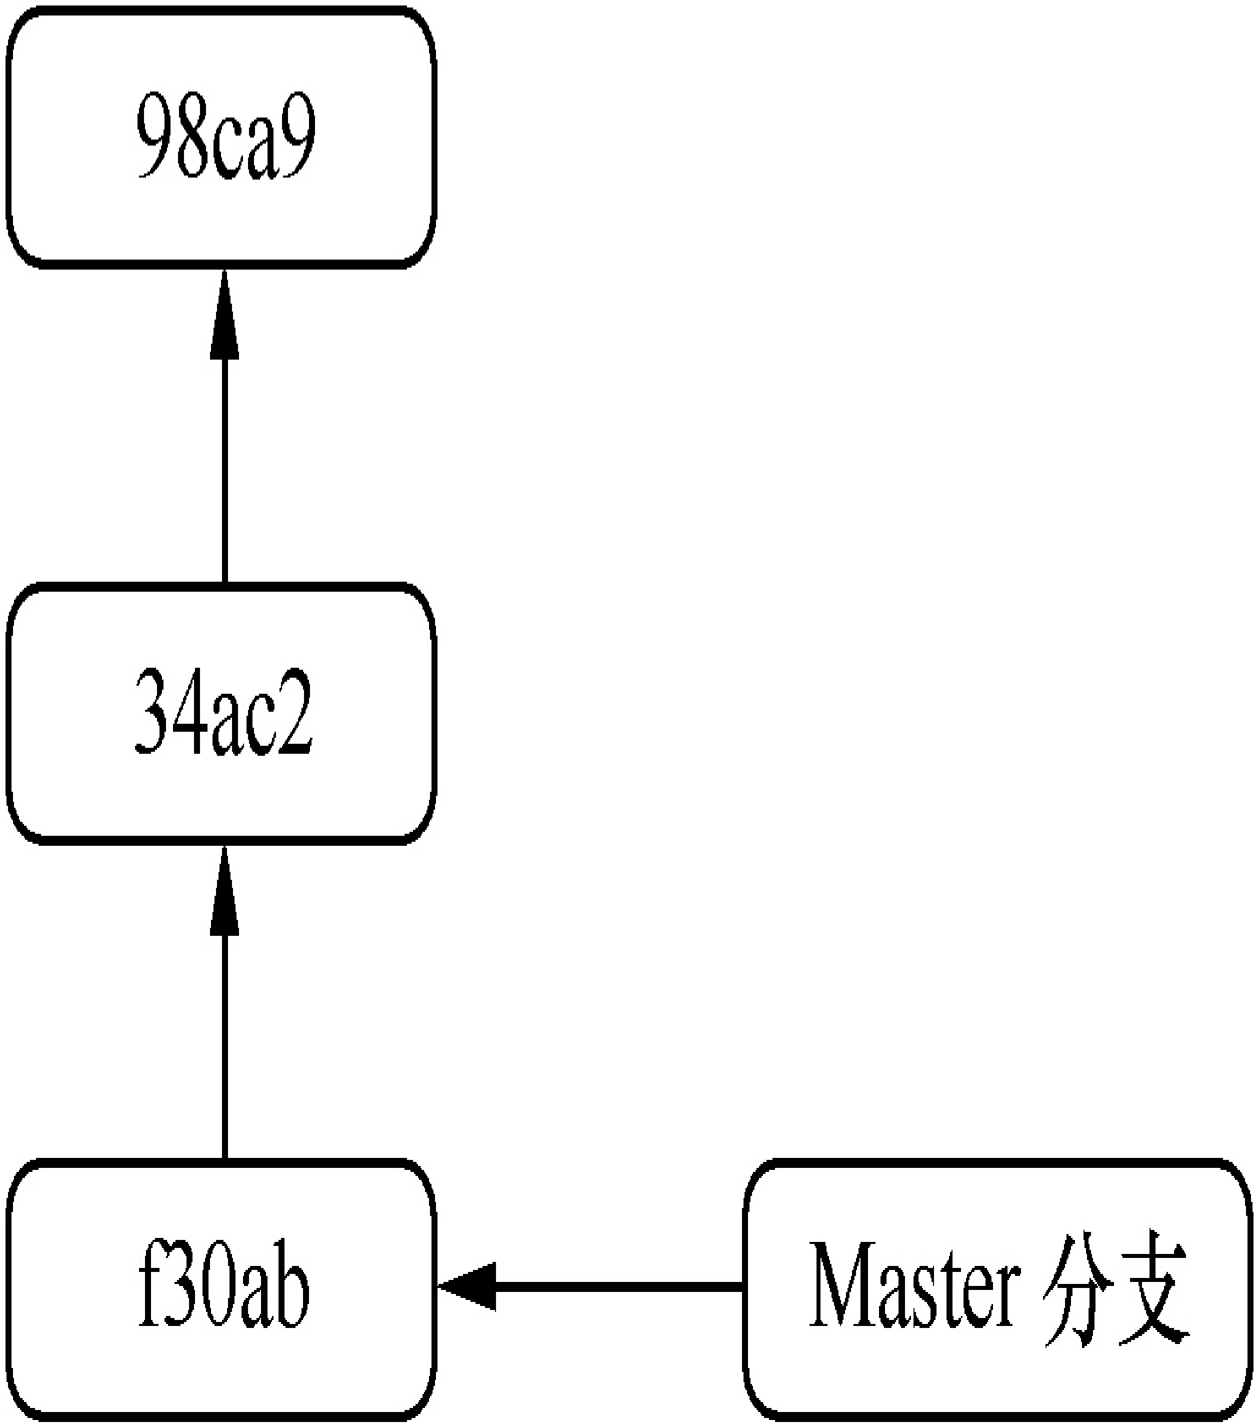

▲图24-16　默认的分支指针示意图节

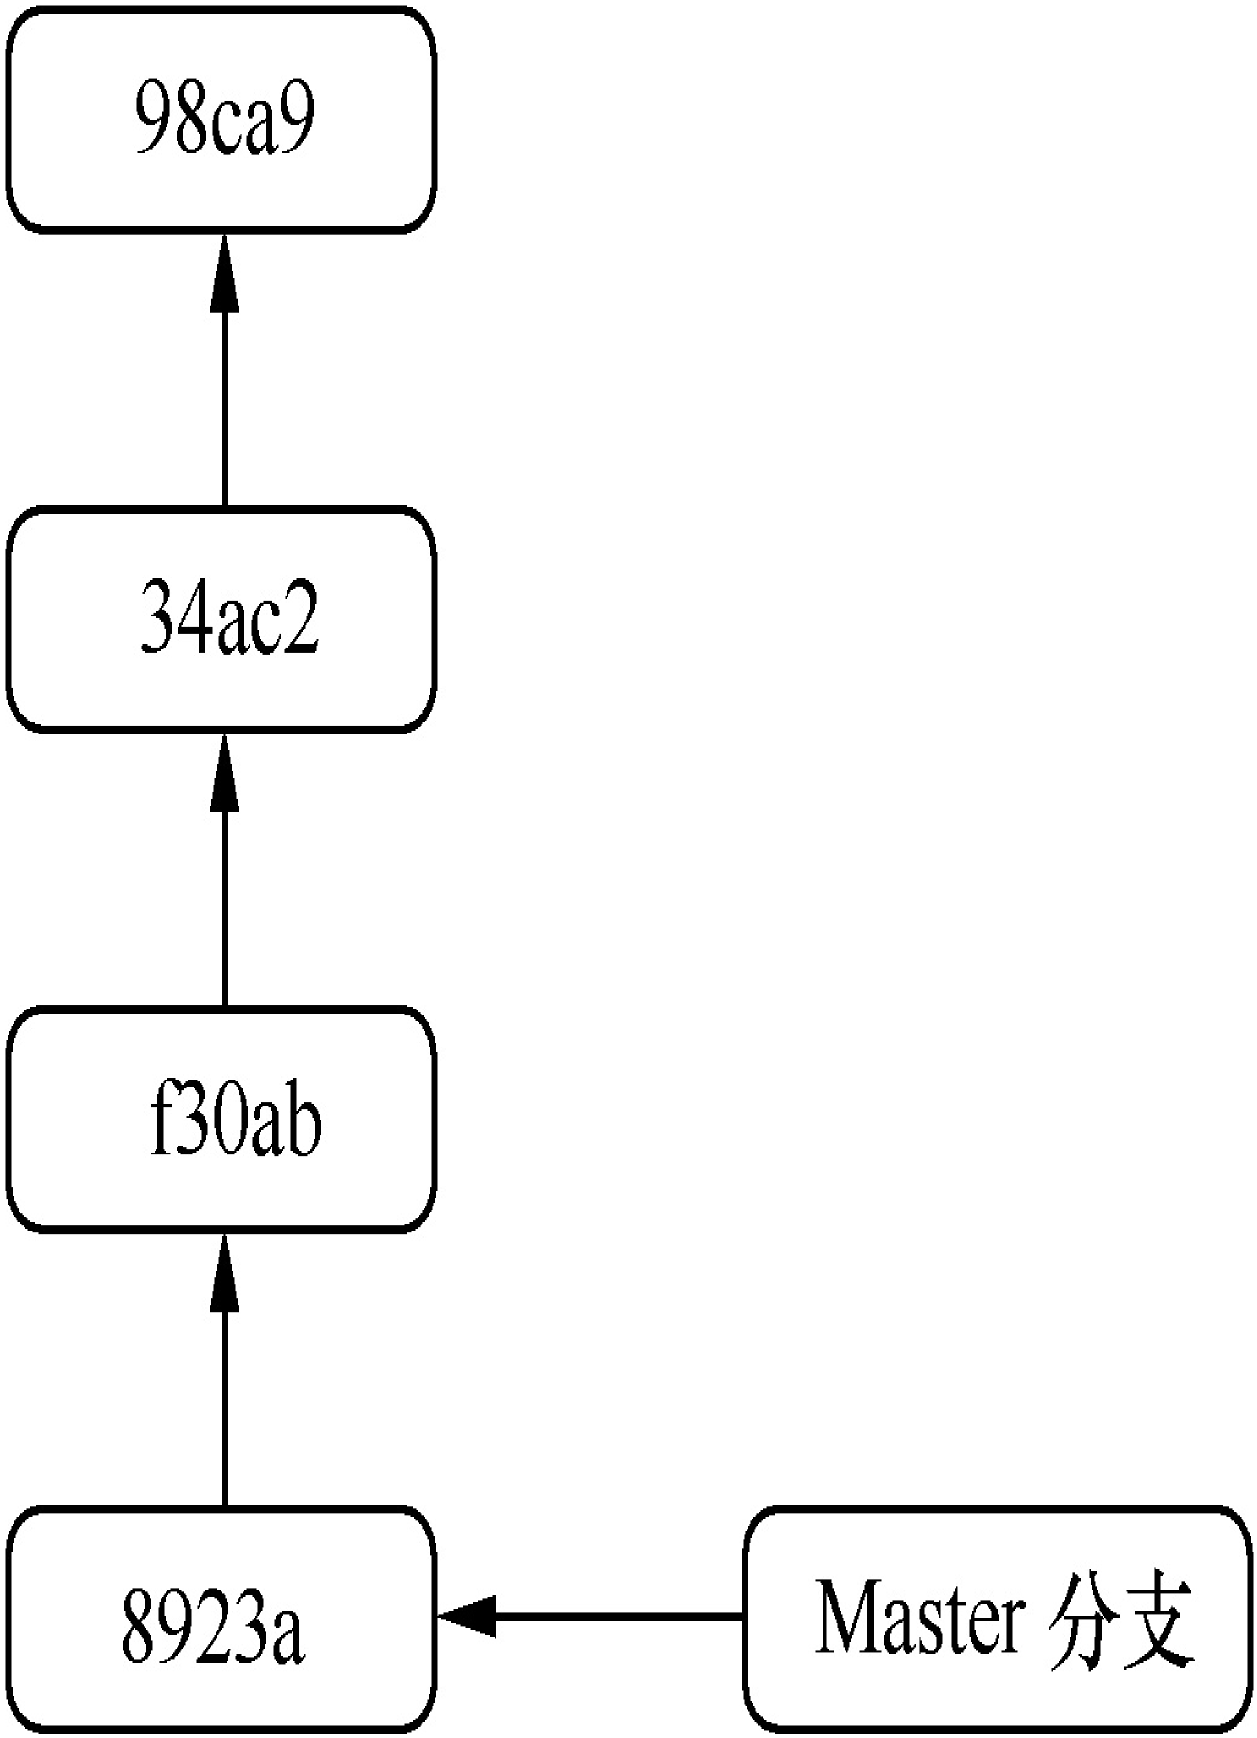
98ca9
34ac2
f30ab
8923a
Master 分支

▲图24-17　分支指针随提交而改变

接下来我们通过实例进一步讲解分支的基本操作。

3. 分支管理的基本操作

明白了分支指针的概念后，我们再来看看多分支的情况。

分支的管理包括新建、查看、删除等多种操作，都可以通过以下命令来完成：

```
git branch [--color[=<when>] | --no-color] [-r | -a]
[--list] [-v [--abbrev=<length> | --no-abbrev]]
[--column[=<options>] | --no-column]
[(--merged | --no-merged | --contains) [<commit>]] [<pattern>...]

git branch [--set-upstream | --track | --no-track] [-l] [-f] <bra

git branch (-m | -M) [<oldbranch>] <newbranch>

git branch (-d | -D) [-r] <branchname>...

git branch --edit-description [<branchname>]
```

比如我们要新建一个名为“branch_basic”的分支，可以使用：

```
git branch branch_basic
```

此时再查看分支情况，可以看到已经创建成功如下所示。

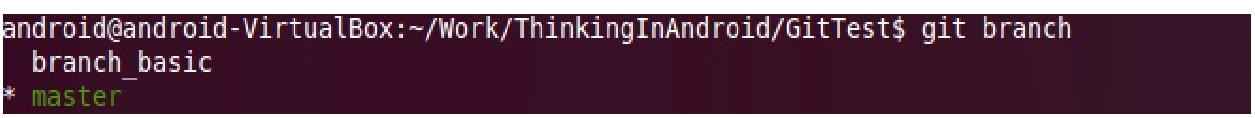

带“*”号的是当前的工作分支。可见虽然我们成功创建了一个新的分支，但并没有切换到这上面来。Git是通过.git目录下的HEAD文件来记录当前的工作分支的。一般情况下，这个文件的格式如下（表示当前在master分支中）：

```
ref: refs/heads/master
```

开发者需要通过以下命令来切换分支：

```
git checkout branch_basic
```

此时就切换到了新分支上，如下所示。

```
* branch_basic
  master
```

而且分支关系图同时发生了变化，如图24-18所示。

就像在C语言中我们会给指针赋予一个初始值一样，Git的新建分支也会有一个原始指向。默认情况下，新的分支的指向和master分支一样。

现在我们对项目文件进行修改，并完成提交动作。这样一来，分支指针也会发生相应的变化，如图24-19所示。

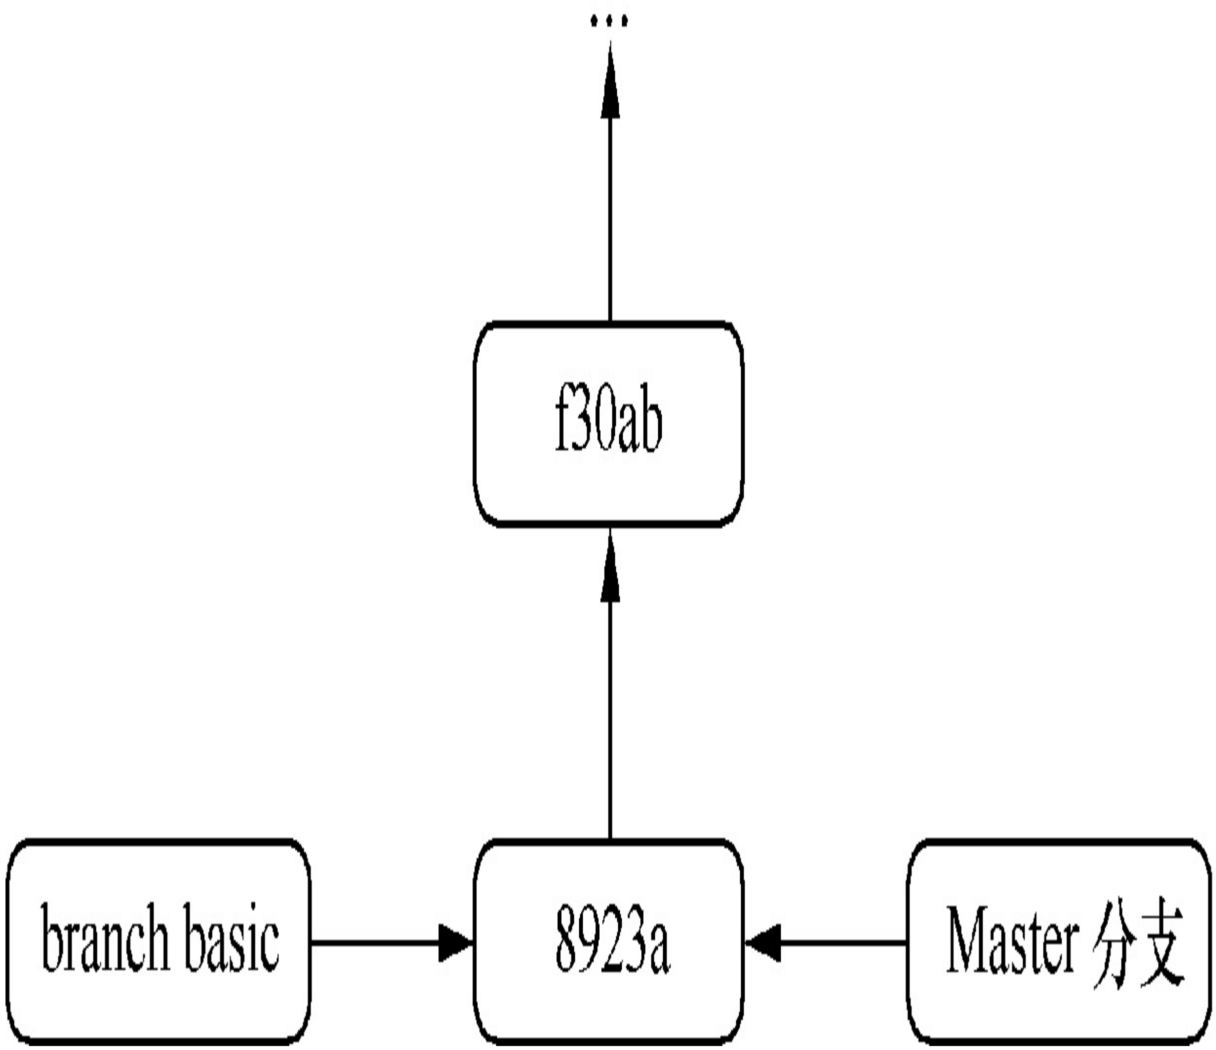

▲图24-18　新建分支的初始值

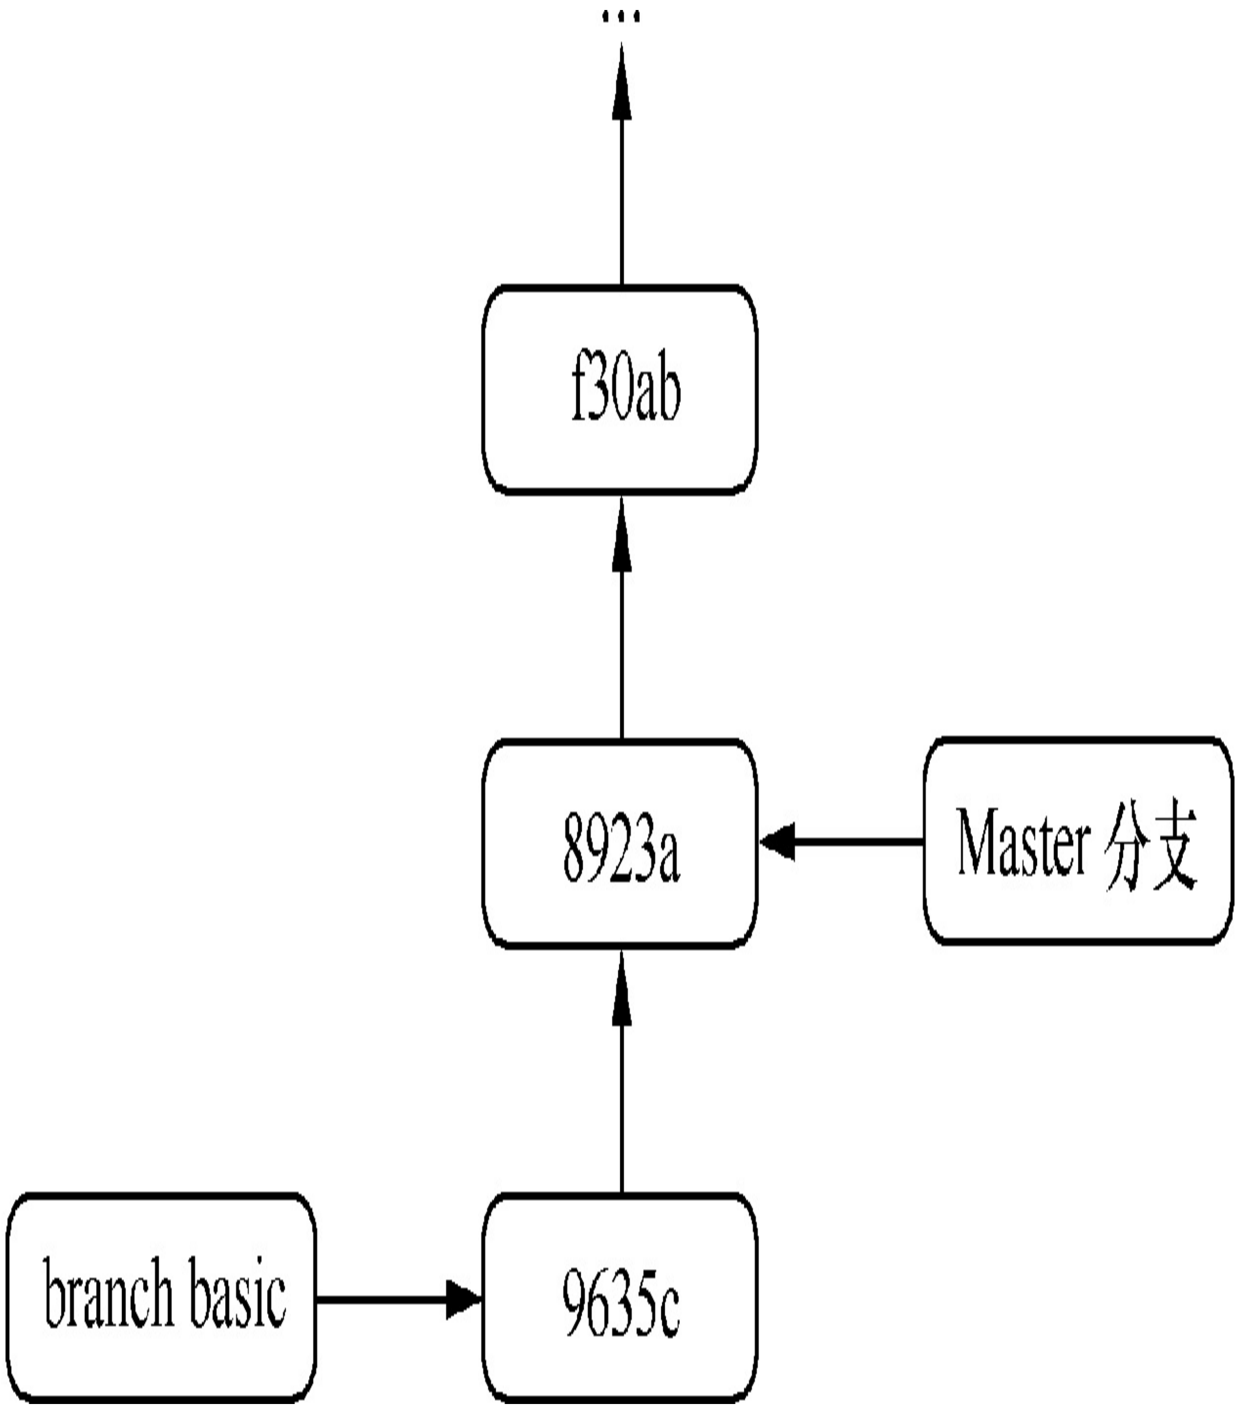

▲图24-19　在新分支上执行提交操作后

此时两个分支就出现了分离。假如此时再次切换回到主分支，然后做一些修改并提交，情况就又有了新变化，如图24-20所示。

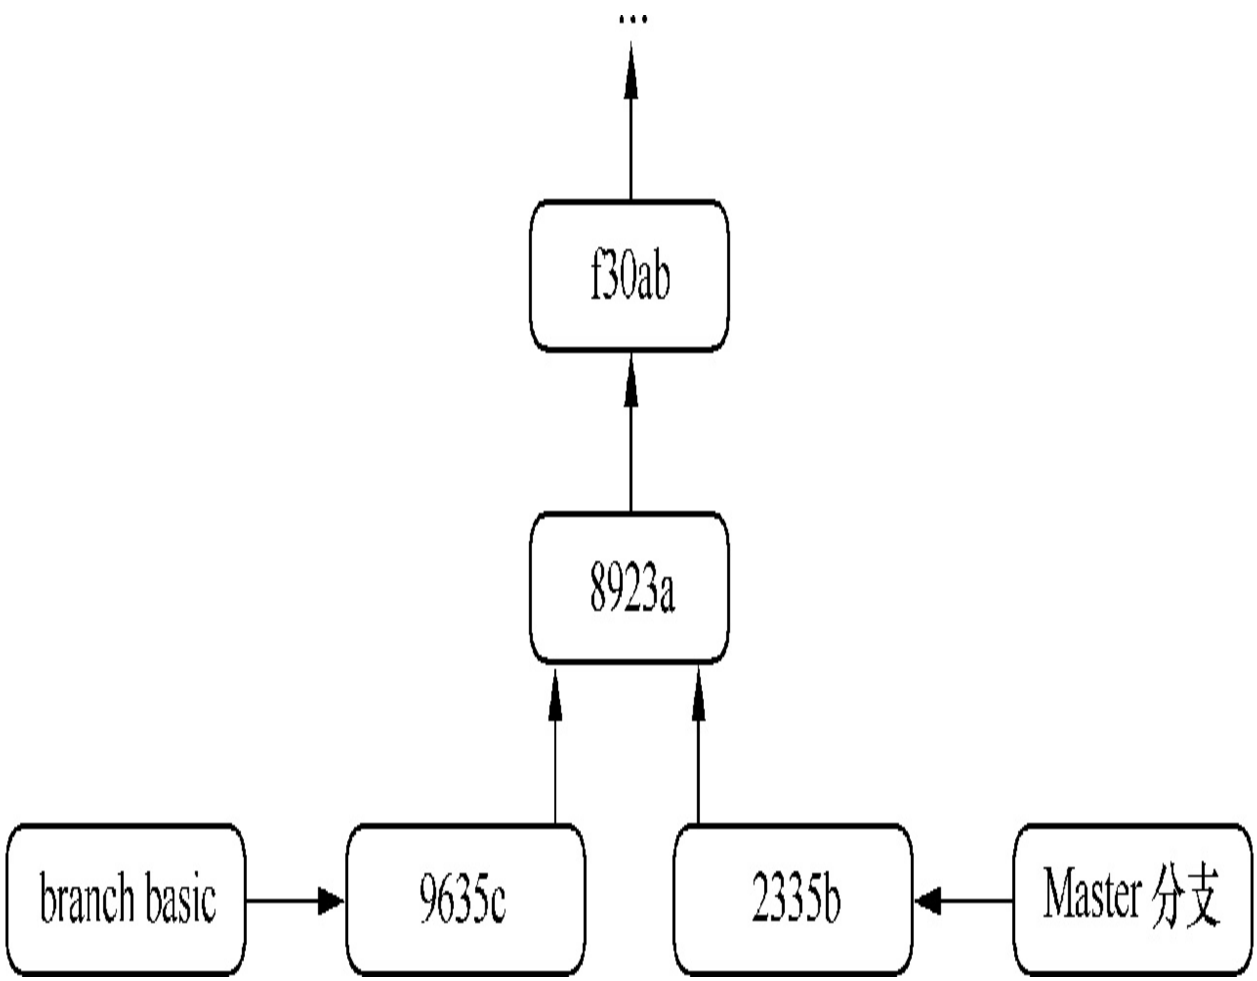

▲图24-20　两分支独立开发的情况

随着开发的推进，会衍生出更多的分支，由此产生各种复杂的情况。不过由于Git中创建分支的高效率，它鼓励开发者新建分支。当然一旦项目开发进展到一定程度，我们还是应该考虑把分支合并到主干上；而且与上图不同的是，我们一般不会让master分支出现在分叉上，而是新建另一分支来完成图中所示的master工作。

4．主干发布，分支开发

目前业界有很多版本分支的管理方式，其中使用非常广泛的一种就是“主干发布，分支开发”。从字面意思上不难理解，这种开发模式的核心思想是将变化的部分（包括新特性，问题修复等）通过拉出分支的方式进行独立开发，来达到保持主干稳定的目的。这样一来在发布新版本的时候，管理员只需要从主干上取代码就可以了；而新开发的特性或者修复的问题亦可以在验证后合并到主分支。同理，“主干开发，分支

发布”的特性也是类似的。总的来说它们各有优缺点，需要根据不同的项目诉求来做正确的取舍。

不论情况多么复杂，版本管理系统所要做的核心工作仍然是我们在本章开头所提出的抽象图。读者可以根据这几个小节的讲解，来仔细思考一下Git是如何完成这些核心工作的。

Git提供的很多其他命令在本章中并没有涉及。另外，它的服务器部署我们也没有去探究。不过我们所讨论的这些命令，都是开发者在实际工程项目中经常会用到的。特别是本章在对Git分析过程中给出的诸如“版本管理抽象图”“分支是指针”等概念，都是这个系统最基础也最核心的设计理念。“万变不离其宗”，相信读者在阅读了本章内容以后再去使用或者深入解析Git，就会发现它已经变得不再难懂了。

第25章 系统调试辅助工具

本章将向读者讲解Android系统调试需要用到的几个核心工具，即Emulator、Android和ADB。

25.1　万能模拟器——Emulator

Android系统中自带的Emulator几乎能模拟“手持设备”的所有硬件和软件特性（除了用户不能拨打实际电话外）——不论对应用程序开发还是系统移植，这都是非常实用的。尤其是对前者，模拟器提供的定制功能让用户可以轻松创建出各种硬件配置的“设备”，这无疑为我们验证产品的兼容性和可靠性节约了大量的时间。

Android的模拟器是基于QEMU的。后者也是一个开源项目，由法国计算机程序员Fabrice Bellard编写。这位实现最快圆周率算法的作者另一知名开源项目是Ffmpeg，感兴趣的读者可以了解一下。

秉承本书的一贯“作用”，我们将先对QEMU进行一定程度的解析——从中让读者明白QEMU“已经做了哪些”，然后再来看看Android“选择了哪些”“废弃了哪些”以及“改良了哪些”。这样即便脱离了Android的环境（如读者想将模拟器运用于其他非Android项目中），也都不会再觉得无从下手了。

接下来将分为两个方向展开——首先，我们会介绍QEMU这个模拟器，让读者对它有个感性的认识；然后我们会讲解Android模拟器从QEMU中继承和扩展出的一些重要特性。

25.1.1　QEMU

1. 虚拟化技术

要想了解QEMU，就需要先补充虚拟化技术的一些背景知识。

虚拟化（virtualization）是对某种事物的虚拟实现——这些事物并不是真实存在的，而是通过特定手段创建出来的。比如目前我们已经可以虚拟出操作系统、存储设备等。虚拟化技术是实现“云计算”的基础，也是当前研究领域的一个热门课题。本章我们主要以硬件虚拟化为讲解重心。

提供虚拟化技术的软件在发展早期被称为“控制程序”，后来则慢慢变为“Hypervisor”或者VMM（Virtual Machine Monitor）。从字面就能看出来，它是运行于其上程序（Guest Software）的控制和监督

者；而且Guest Software并不只局限于某种程序，某些情况下它甚至是指整个操作系统。如在工程项目中，我们经常需要在虚拟机上运行Windows或者Linux操作系统，如图25-1所示。

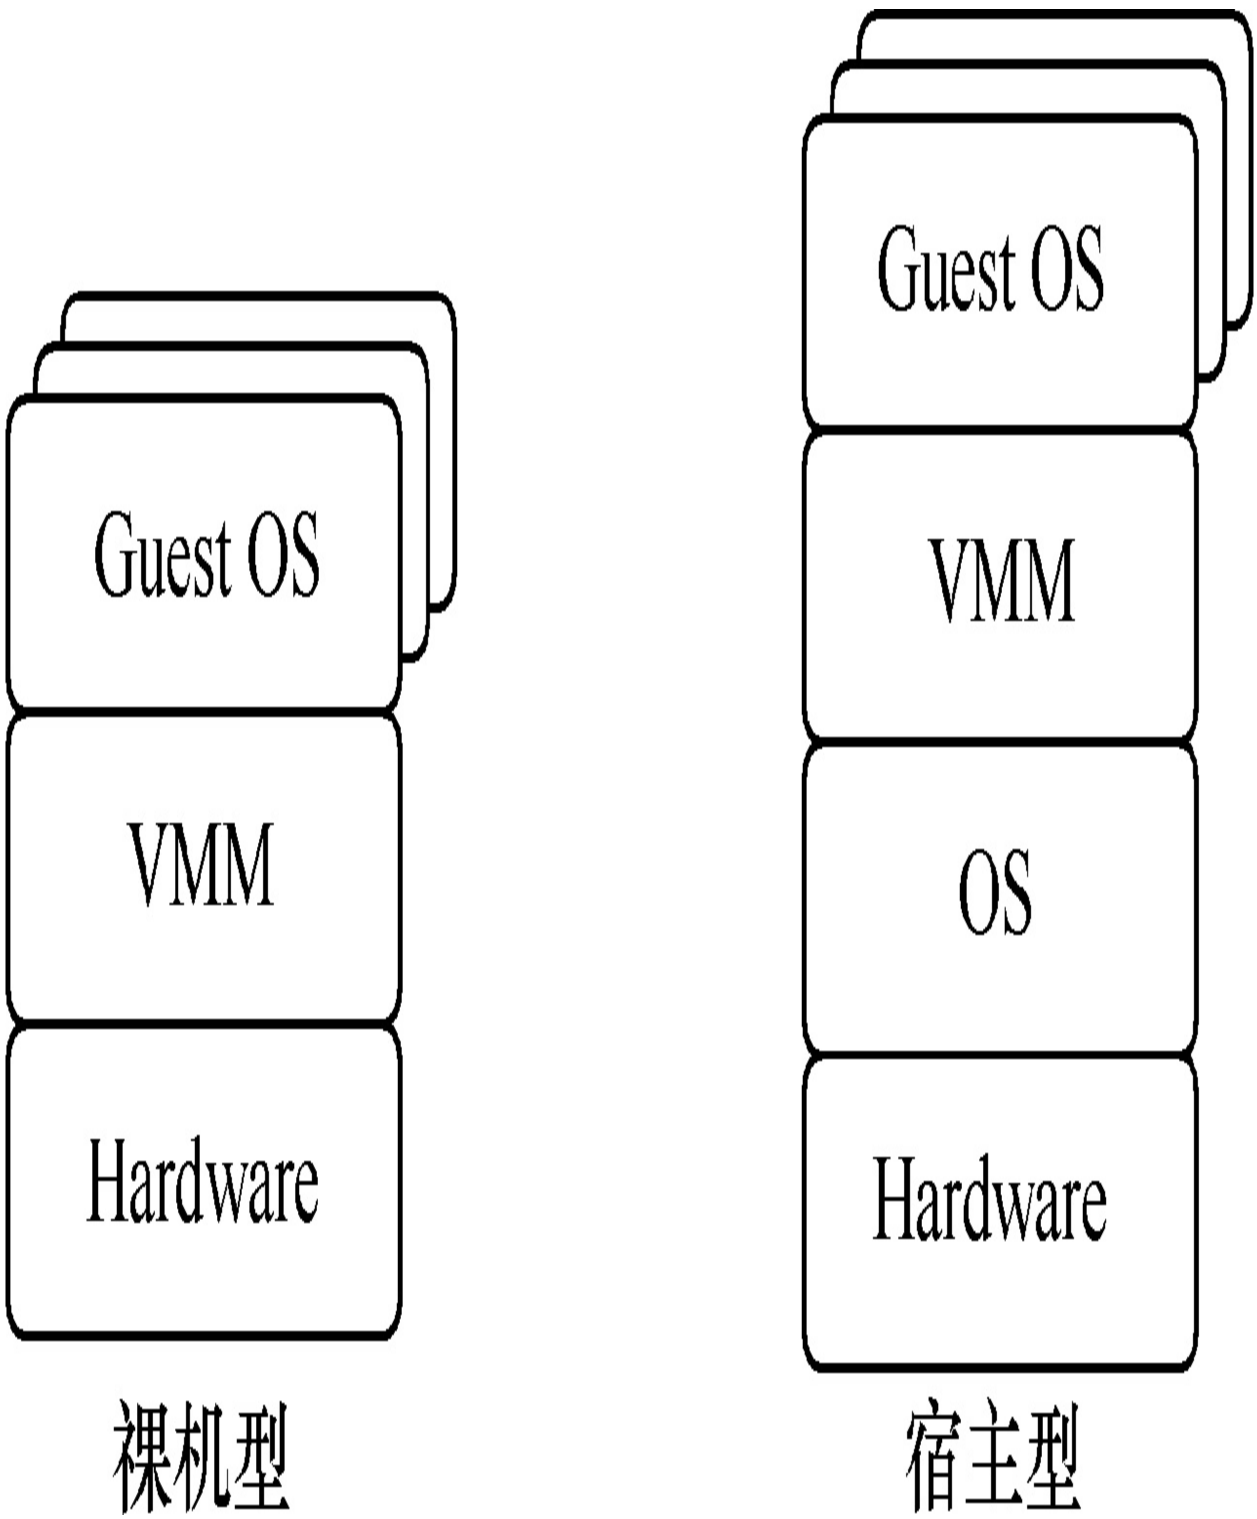

▲图25-1　虚拟机

根据VMM的功能描述，我们可以很自然地联想到：它的运行环境是什么样的呢？

- 对于直接在底层硬件上执行的VMM，我们称为Native或者Bare Metal型。

这种方式不需要底层操作系统的支持，因为VMM本身就是宿主。目前这类虚拟机中比较有名的有：Oracle VM Server for SPARC、KVM（Kernel Virtual Machine）、VMWare EXS/ESXi以及Microsoft Hyper-V等。

- 同样，如果是安装于其他操作系统之上的VMM，就被称为hosted类型。它的宿主操作系统通常只是普通的操作系统。比如我们在Windows操作环境中安装的VirtualBox就属于这种方式。其他比较受欢迎的此类VMM有：VMWare Workstation、Bhyve等。

除了自身的运行环境外，VMM为Guest OS提供的支撑方法也有多种分类，以下列出其中比较核心的几种。

- 全虚拟化（Full virtualization）

全虚拟化可以让运行于其上的客户操作系统不用做任何修改。可想而知，这就要求VMM提供完整的硬件模拟，包括处理器、物理内存、各种外设、时钟等。这种技术的难点是如何实现客户操作系统特权指令的执行。因为在VMM的控制下，可能会有不止一个客户操作系统存在。它们都被禁止改变对方的状态，或者去篡改VMM的运行值。对于这一问题，不同的VMM开发商有各自的实现——同时这也是影响VMM执行效率的重要因素之一。

这种虚拟技术的优点是不需要更改Guest OS，因此得到了广泛的应用。我们所熟悉的，如Oracle VM、Virtual PC、Vmware Workstation、KVM、QEMU、Paralles Workstation等都采用了这种技术。

- 半虚拟化（Partial virtualization）

又翻译为“部分虚拟化”，是和“全虚拟化”类似的一种技术。它们都为Guest OS提供了硬件的模拟，只不过半虚拟化技术需要让Guest OS根据自己提供的接口做部分修改，以符合诸如特权指令运行的要求。

这种方式的优点在于整体运行速度比全虚拟化要快，而且架构也精简些；缺点也很明显，即需要Guest OS做相应修改。这类VMM的代表有Xen以及Microsoft Hyper-V等。

- 硬件辅助虚拟化（Hardware-assisted virtualization）

准确地说，这种技术是用于协助上面两种方式来完成优化的。硬件辅助的意思是，借助于专门针对虚拟化技术而提供的硬件支持来大幅改善上述方法中的不足，以使VMM的运行速度更加接近于实际物理机。当前众多主流的虚拟机产品都支持硬件辅助，如Virtual Box、Vmware Workstation、Microsoft Virtual PC、KVM和Xen等。

明白了虚拟化技术的分类、功能及工作方式后，我们再切入QEMU应该就不会感到陌生了。

2．QEMU简介

读者之前如果没有接触过QEMU，那么最好先去阅读以下几篇文章。

- “QEMU, a Fast and Portable Dynamic Translator”，Fabrice Bellard，http://static.usenix.org/publications/library/proceedings/usenix05/tech/freenix/full_papers/

  这是QEMU作者写的一篇论文，具有绝对的权威性。

- “QEMU Emulator User Documentation”，http://qemu.weilnetz.de/qemu-doc.html

  这篇文章是QEMU使用指南，可以作为入门文档。

- 对于开发者而言，如果想学习QEMU内部实现原理或者希望修改QEMU源码，可以参阅官方推荐的指南。

总的来说，QEMU有两种工作模式。

- 全系统模式

在这种方式下，QEMU可以模拟出一个完整的系统，包括若干个处理器和外围设备。

- 用户模式

在这种方式下，QEMU可以在一个CPU上运行针对另一CPU所编译的程序。

在全系统模式下，QEMU支持以下硬件设备：

PC（x86 or x86_64 processor）

ISA PC（old style PC without PCI bus）

PREP（PowerPC processor）

G3 Beige PowerMac（PowerPC processor）

Mac99 PowerMac（PowerPC processor， in progress）

Sun4m/Sun4c/Sun4d（32-bit Sparc processor）

Sun4u/Sun4v（64-bit Sparc processor，in progress）

Malta board（32-bit and 64-bit MIPS processors）

MIPS Magnum（64-bit MIPS processor）

ARM Integrator/CP（ARM）

在用户模式下，支持的硬件设备为：

x86（32 and 64 bit）

PowerPC（32 and 64 bit）

ARM，MIPS（32 bit only）

Sparc（32 and 64 bit）

Alpha，ColdFire(m68k)

CRISv32和MicroBlaze CPU

3．QEMU的安装与编译

在使用QEMU前，我们需要先安装它。和大部分软件一样，它既可以直接使用安装包的形式来安装，也可以通过源码编译后再进行安装。

如果是选择前者，可以在系统中使用以下命令。

Debian/Ubuntu：

```
$ sudo apt-get install qemu
```

Red Hat/ Fedora：

```
$ yum install qemu
```

Gentoo：

```
$ emerge qemu
```

如果希望通过源码编译来安装，下载地址是：

```
$ git clone git://git.qemu.org/qemu.git
```

编译过程很简单，可以选择在Linux或者Windows下完成操作，甚至也可以在Linux下编译Windows版本的QEMU。我们推荐在Linux下编译生成可执行程序。方法如下：

```
#下载后，先解压QEMU源码包
$ ./configure
$ make
$ make install #就这么简单
```

4．QEMU的常用功能

下面分几个类别来讲解QEMU的常用功能。

（1）标准选项如表25-1所示。

表25-1　标准选项

选　　项	说　　明
-h	显示帮助然后退出
-version	显示版本信息然后退出
-machine [type=]name[,prop=value[,...]]	选择被模拟的机器。可以使用-machine?来获知可使用的机器列表
-cpu model	选择CPU模式。同样可以使用-cpu?来获得可用的选项列表
-smp n[,cores=cores][,threads=threads][,sockets=sockets][,maxcpus=maxcpus]	设置模拟的CPU数目。不同硬件设备支持的最大CPU数量是不同的。比如PC机支持的最大数是255个，而Sparc32则只有4个
-fda file -fdb file -hda file -hdb file -hdc file -hdd file -cdrom file	将file所指向的文件作为系统的相应存储器设备

-drive option[,option[,option[,...]]]	新建一个设备
-mtdblock file	以file指定的文件作为板上的FLASH存储设备
-sd file	以file指定的文件作为SD卡设备
-boot [order=drives][,once=drives][,menu=on|off][,splash= sp_name][,splash-time=sp_time]	设定启动顺序
-m megs	设置虚拟内存大小（M字节）。默认值是128MB
-k language	设置键盘语言，如fr表示法语。默认情况下是en-us
-audio-help	显示音频子系统帮助

（2）USB选项如表25-2所示。

表25-2　USB选项

选　　项	说　　明
-usb	使能USB驱动

-usbdevice devname	添加USB设备，如鼠标、移动硬盘、串口设备等
-device driver[,prop[=value][,...]]	添加设备驱动

（3）文件系统选项如表25-3所示。

表25-3　文件系统选项

选　项
-fsdev fsdriver,id=id,path=path,[security_model=security_model][,writeout=writeout][,readonly][,socket=socket|sock_fd=sock_fd]
-virtfs fsdriver[,path=path],mount_tag=mount_tag[,security_mode\l=security_mode [,writeout=writeout][,readonly][,socket=socket|sock_fd=sock_fd]
-name name
-uuid uuid

（4）显示选项如表25-4所示。

表25-4　显示选项

选　项	说　明
-display type	设置显示类型
-nographic	将QEMU变为命令行样式
-alt-grab	通过Ctrl+Alt+Shift按键来获取鼠标
-ctrl-grab	通过右Ctrl键来获取鼠标
-spice option[,option[,...]]	使能spice远程桌面协议
-rotate	将图形左转
-full-screen	全屏显示
-g widthxheight[xdepth]	设置初始图形分辨率和深度

（5）网络选项如表25-5所示。

表25-5　网络选项

选　项	说　明

-net nic[,vlan=n][,macaddr=mac][,model=type][,name=name][,addr=addr][,vectors=v]	创建新的网络接口
-net user[,option][,option][,...]	使用用户模式的网络栈
-net tap[,vlan=n][,name=name][,fd=h][,ifname=name][,script=file] [,downscript=dfile][,helper=helper]	VLAN连接
-net bridge[,vlan=n][,name=name][,br=bridge][,helper=helper]	设置桥接

（6）针对Linux/Multiboot如表25-6所示。

表25-6　针对Linux/Multiboot

选　项	说　明
-kernel bzImage	将bzImage指定的文件作为内核映像文件
-initrd file	设置系统的initial ram disk
-dtb file	设置dtb映像文件

（7）调试选项如表25-7所示。

表25-7　调试选项

选　项	说　明

-serial dev	为模拟器指定串口设备。比如在Windows下，可以通过-serial COMn来指定模拟器需要使用宿主机的某个串口
-monitor dev	将虚拟机的monitor转向到主机的dev上
-pidfile file	将QEMU的进程PID保存到file中
-singlestep	以单步调试的模式运行模拟器
-S	系统开始时不要启动CPU，只有当输入'c'时才继续
-gdb dev	等待gdb的连接
-s	-gdb tcp::1234的简写
-d	输出log文件到/tmp/qemu.log
-D logfile	将上面的log保存到logfile路径中
-L path	设置BIOS、VGA BIOS和键盘布局文件地址的目录
-bios file	设置BIOS文件名。结合上面选项找到BIOS文件

-enable-kvm	使能KVM的全虚拟支持。这个选项只有当我们在编译时打开了KVM支持选项才有效
-no-reboot	退出而不是重启
-no-shutdown	当guest关机时，不退出而是停止模拟器
-loadvm file	以文件file中保存的系统状态启动
-show-cursor	显示鼠标cursor
-readconfig file	从file中读取系统配置文件
-writeconfig file	将系统配置文件写入file中

以上几个列表给出了QEMU最常见的一些用法。接下来在Android模拟器的学习过程中，读者可以思考：

- Android模拟器继承了QEMU的哪些“基因”；
- 如何从QEMU入手来为Android模拟器添加新功能。

25.1.2 Android工程中的QEMU

Android项目中的QEMU源码主体在external/qemu中。不过我们并不

分析它的源码实现，而是从它提供的功能和特性中来体会Android对QEMU的改进。

1．命令行基本用法

使用Android模拟器的一般格式为：

emulator -avd <avd_name> [-<option> [<value>]] ... [-<qemu args>]

它所提供的选项非常丰富，下面将分为多个类别来分别说明。

（1）使用AVD如表25-8所示。

AVD为模拟器z提供了一个“虚拟设备”（外观、基本的硬件配置等都是可以调整的，可以参见下一小节关于Android工具的讲解）。

表25-8　使用AVD

选　　项	说　　明
-avd <avd_name>	为模拟器指定一个AVD。这个选项是必需的

（2）磁盘映像文件如表25-9所示。

表25-9　磁盘映像文件

选　　项	说　　明
-cache <filepath>	设置cache分区的映像文件 如果没有，系统将创建一个临时文件来代替
-data <filepath>	设置user-data的映像文件。如果没有，系统会寻找名为userdata-qemu的映像文件来代替

-initdata <filepath>	当利用-wipe-data重置user-data时，将这里指定的文件复制到新的user-data；否则模拟器将复制<system>/userdata.img的值
-nocache	不使用cache分区
-ramdisk <filepath>	设置ramdisk映像文件
-sdcard <filepath>	设置SD卡映像文件
-wipe-data	重置user-data。见上面-initdata的描述

（3）系统相关如表25-10所示。

表25-10　系统相关

选　项	说　明
-cpu-delay <delay>	为CPU设置延迟。有效值是0～1000
-gps <device>	重定向兼容NMEA的GPS到某个字符设备。注意：设备的书写必须符合QEMU串口设备的格式。可以参见前面QEMU的“-serial -dev”选项
-nojni	运行时关闭JNI检查

-qemu	传递参数给QEMU。注意：如果使用此选项，必须保证它是放在最后面的，因为其后的所有选项都将被认为是要传递给QEMU的
-qemu -enable-kvm	使能KVM加速。这个选项只有当系统编译时选择了支持KVM才会有效
-qemu -h	显示帮助信息
-gpu on	打开GPU图形加速
-radio <device>	将radio设备重定向到字符设备。格式同上面-gps的描述
-timezone <timezone>	设置时区信息，而不是用模拟器所在主机的时区
-version	显示版本号

（4）UI相关如表25-11所示。

表25-11　UI相关

选　　项	说　　明
-dpi-device <dpi>	设置模拟器的dpi值，默认值为165

-no-boot-anim	关闭模拟器的启动时动画
-no-window	关闭模拟器的图形窗口显示
-scale <scale>	调整显示窗口的比率。有效值为： ● 0.1～3，表示调整因子 ● <数值>dpi ● Auto。表示让模拟器自动选择最佳数值
-noskin	不使用模拟器外观
-keyset <file>	使用指定的键盘绑定。即主机按键与模拟器按键的对应关系
-onion <image>	使用指定的overlay图像
-onion-alpha <percent>	设置onion外观的透明度，默认值为50
-onion-rotation <position>	设置onion外观的位置，必须是0、1、2或3

（5）网络相关如表25-12所示。

表25-12　网络相关

选　　项	说　　明

-dns-server <servers>	设置DNS服务器
-http-proxy <proxy>	设置HTTP/HTTPS代理 格式为： http://<server>:<port> http://<username>:<password>@<server>:<port>
-netdelay <delay>	设置网络延迟值，模拟比较真实的网络环境
-netfast	即 -netspeed full -netdelay none
-netspeed <speed>	设置网络速度，默认值为full。可选值有如下几种： ● gsm（GSM/CSD） Up: 14.4, down: 14.4 ● hscsd（HSCSD） Up: 14.4, down: 43.2 ● gprs（GPRS） Up: 40.0, down: 80.0 ● edge（EDGE/EGPRS） Up: 118.4, down: 236.8 ● umts（UMTS/3G） Up: 128.0, down: 1920.0 ● hsdpa（HSDPA） Up: 348.0, down: 14400.0 ● full（no limit） Up: 0.0, down: 0.0 ● <num> 自定义上传和下载值都为num ● <up>:<down> 分别设置上传和下载值为up和down

（6）调试相关如表25-13所示。

表25-13　调试相关

选　　项	说　　明
-logcat <logtags>	使能logcat输出。注意：为了不影响运行效率，部分手机厂商对logcat进行了过滤和控制，这种情况下开发者需要到厂商指定的设置中去手动打开logcat功能
-shell	创建一个root权限的shell终端
-shell-serial <device>	使能root权限的终端并指定字符设备来与之通信
-show-kernel <name>	打印内核信息
-trace <name>	使能代码追踪，并写入指定文件
-verbose	使能verbose模式的输出，等价于-debug-init

（7）帮助信息相关如表25-14所示。

表25-14　帮助信息相关

选　　项	说　　明
-help	显示一系列模拟器选项的帮助信息
-help-all	显示启动选项的帮助信息
-help-<option>	显示特定启动选项的帮助信息
-help-debug-tags	显示 –debug <tags>的帮助信息
-help-disk-images	显示模拟器硬盘映像文件的使用帮助
-help-environment	显示模拟器环境变量帮助
-help-keys	显示当前按键的绑定信息，参见“-keyset <file>”选项的说明
-help-keyset-file	显示如何定义新的按键绑定
-help-virtual-device	显示如何使用AVD

25.1.3　模拟器控制台（Emulator Console）

我们知道，Android系统的每个模拟器都将占用两个端口。其中一个用于和adb进行通信，另一个就是控制台专用端口——由此可见，模拟器控制台的端口号一定是偶数。控制台为自动化测试提供了强有力的保障，读者可以参考本书中讲解测试内容的章节来了解更多信息。

连接一个控制台的语法如下：

```
telnet localhost &lt;console_port>
```

如果不清楚console_port的具体值，可以先用adb devices进行查询。

完成连接后将会有如下提示。

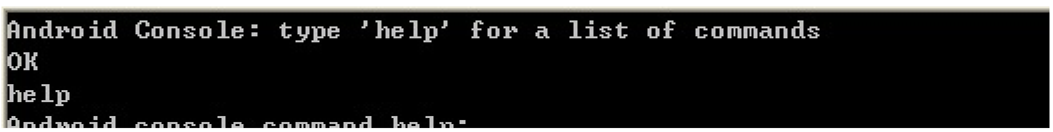

然后我们就可以向模拟器发送命令了。通用格式如下：

命令<空格>子命令

例如利用sms命令发送一条短信给模拟器，应遵循如下格式：

```
sms    send     12345          content
```
命令子命令号码（参数）内容（参数）

表25-15详细描述了Emulator Console中的常见命令，以供读者查阅。

表25-15 Emulator Console中的重要命令一览表

命　　令	子命令	参　　数	说　　明
avd	name		显示当前控 模拟器名
	status		该模拟器的
	start		启动模拟器 avd stop后的

模拟器的状态控制	stop		停止模拟器 拟器处于挂 会主动关闭
	snapshot	list	用于“截屏拷
		save <name>	
		load <name>	
		del <name>	
cdma	ssource	<source>	设定当前的 阅（subscri
	prl_verstion	<version>	导出CDMA 本
event 向模拟器发送硬件事件，这条命令在自动化测试中是比较常用的	Send	<type>:<code>:<value> [...]	向模拟器发 件，其中<t 值可以分别 和codes子命
event 向模拟器发送硬件事件，这条命令在自动化测试中是比较常用的	types	NONE	列出所有支 别名，如下 EV_SYN EV_REL EV_ABS EV_MSC EV_LED EV_REP EV_PWR EV_FF_STA EV_MAX
	codes	<type>	查询某个类 代码数量： （405个） EV_REL EV_ABS 其余类型（

			比如EV_RE 为： REL_X REL_Y
	event text	<message>	发送组成<n 键事件流
geo 发送地址位置信息（GPS）给模拟器	fix	<longitude><latitude> [<altitude>]	提供GPS修 <longitude> 进制表示 <latitude>:纟 制表示 <altitude>:高 单位
	nmea	<sentence>	发送一个NI 的句子给模 支 持"$GPGG
	call	<phonenumber>	模拟一个来
	accept	<phonenumber>	将一个通话 至"active"— 个通话处于 者"held"
	busy	<phonenumber>	挂断一个去 态改为"bus 通话处于"w
	cancel	<phonenumber>	结束一个来
	data	<state>	改变GPRS数 态，可选值 ● unregister 可用网络 ● home —— 络中 ● roaming – ● searching 网络

gsm 模拟GSM通信，如电话、GPRS数据等			● denied —— 可用 ● off ——无 同unregister ● on ——和 样
	hold	<phonenumber>	将状态改为 提是当前状 为“active”或
	list	NONE	列出当前所 它们的状态
	voice	<state>	改变GPRS语 可选值为： ● unregister 网络 ● home —— 中 ● roaming – ● searching ● denied —— 可用 ● off ——无 ● on ——正
	status	NONE	当前GSM数 态
kill	NONE	NONE	关闭模拟器
network 管理网络连接相关设置	status	NONE	当前网络的 前的上传和
	speed	<speed>	动态改变网 参数请参见 网络相关描
			可以通过设 模拟尽可能 境，可选参 秒为单位）

network 管理网络连接相关设置	delay	<delay>	● gprs GPRS（150 ● edge EDGE/EGPI 400） ● umts UMTS/3G（ ● none 没有延迟 ● <num> 模拟精确的 以“毫秒”为 ● <min>:<m 设置“延迟僱
network 管理网络连接相关设置	capture	start <file>	捕获“网络&
		stop	停止捕获
power 电池和充电状态	display	NONE	显示电池和
	ac	<on|off>	开启/关闭A
	status	<unknown|charging|discharging|not-charging|full>	将电池状态 态
	present	<true|false>	设置电池存
	health	<unknown|good|overheat|dead|overvoltage|failure>	设置电池的
	capacity	<percentage>	设置剩余电 100）
quit/exit	NONE	NONE	退出控制台
qemu	monitor	NONE	进入qemu n 然后可以发 命令，如inf eject等。详 参见qemu的 档。这一命 拟器的高级 些情况下可

			用
redir 管理端口转向（Port Redirection）	list	无	列出当前所
	add	<protocol>:<host-port>:<guest-port>	新增一个端 <protocol>: 可以是“tcp” <host-port>: host上需要扌 <guest-port> 数据将要路 口号
	del	<protocol>:<host-port>	删除一个端 同上
sms 短信	send	<senderPhoneNumber> <textmessage>	模拟SMS来 <senderPhon 电信号码 <textmessag
	pdu	<hexstring>	发送SMS PI
sensor 管理传感器信息	status	NONE	列出当前所 态信息，包 acceleration magnetic-fie orientation （ 器） temperature proximity
	get	<sensorname>	得到某个传
	set	<sensorname><value-a>[:<value-b>[:<value-c>]]	设置某个传
window	scale	<scale>	改变模拟器

25.1.4　实例：为Android模拟器添加串口功能

使用过Android模拟器的读者应该会发现，它没有提供串口功能。这对于应用开发人员来说影响不大，因为他们基本上不会有类似需求。但是对于系统工程人员来说，串口的使用还是比较广泛的。比如不少Android产品要求通过串口去控制蓝牙、GPS模块；或者产品与IPOD设备通过串口进行连接通信等。

可想而知，如果我们能在Android模拟器上仿真串口功能，那么就可以大大减少程序开发和调试上的麻烦，如图25-2所示。

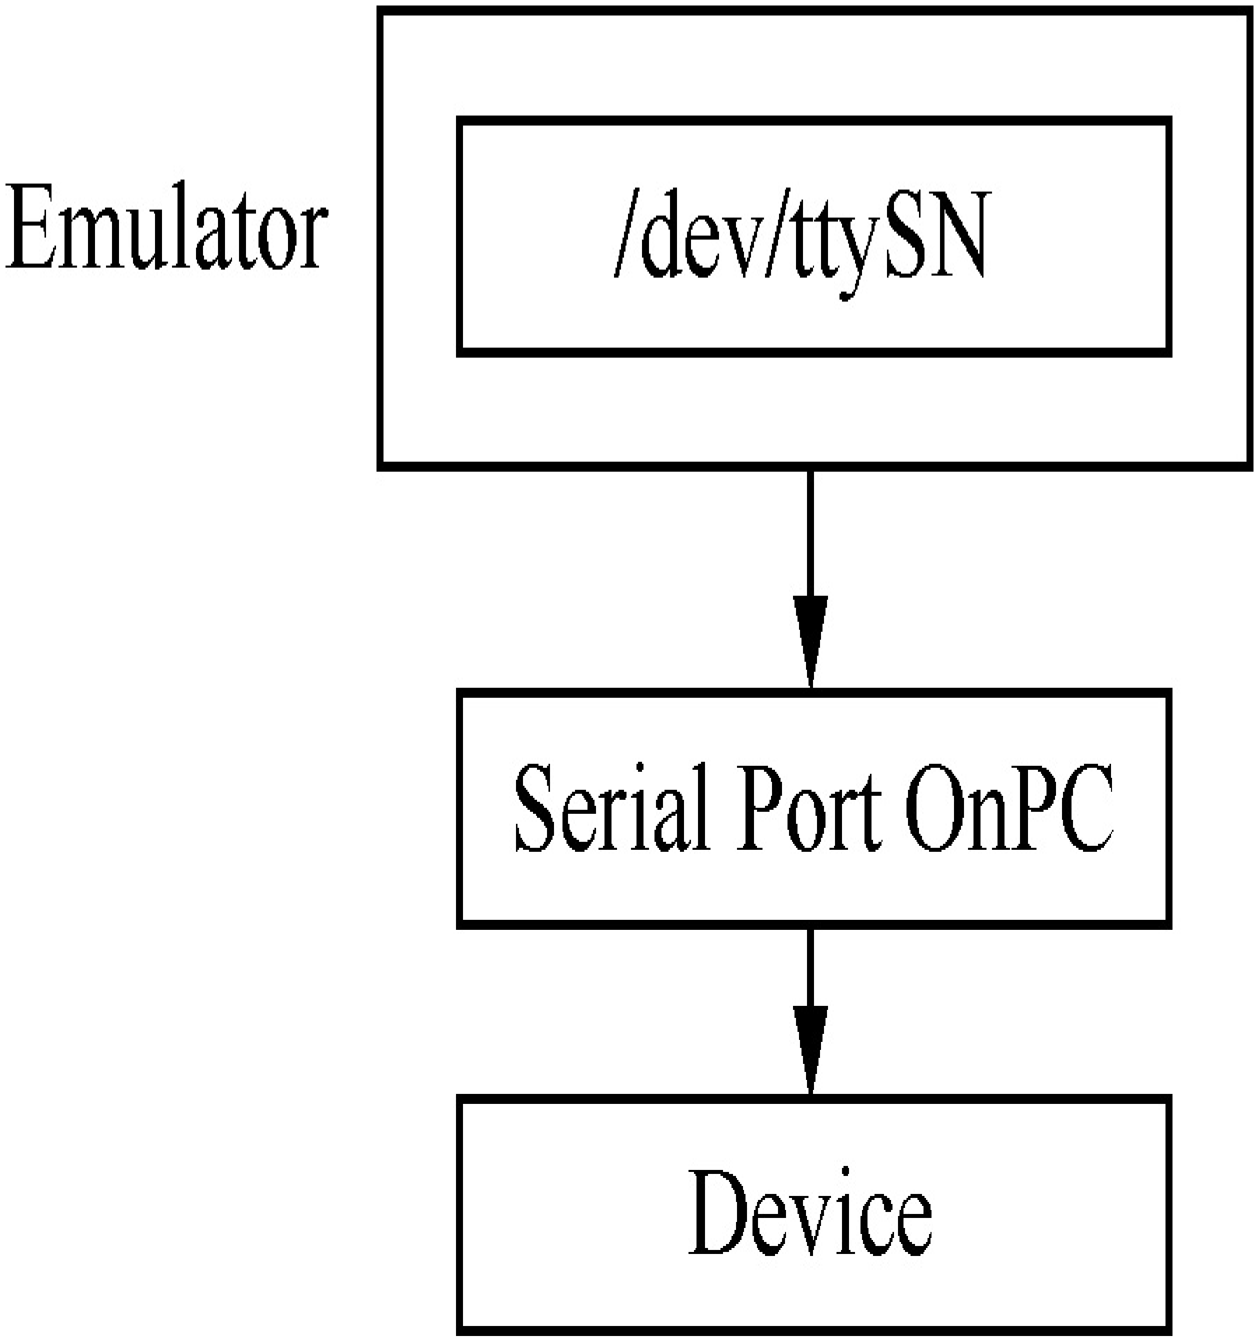

▲图25-2　模拟器

接下来分步骤说明上图的实现过程。

（1）首先需要启动一个带串口的模拟器。根据前几个小节的分析，读者应该已发现QEMU本身是支持串口模拟的，只是Android没有继承这一“基因”——因此我们可以通过向QEMU传递参数来达到目的。比如在Windows操作系统环境下，可以建立如下脚本：

```
"C:\Program Files\Android\android-sdk\tools\emulator" -avd Device
```

第一个参数是emulator程序本身，最好用双引号来将整个路径包含起来。

-avd选项指明需要启动的AVD，也可以根据需要来指定具体的system，kernel等映像文件。这里我们采用的都是默认的系统映像。

最后，我们通过-qemu选项传入需要模拟的串口，即COM1。这个COM1是PC主机上真实存在的串口设备（可以通过Windows中提供的设备管理器来查看）。当然，我们也可以创建虚拟的串口。比如利用软件工具在机器中创建一对虚拟串口COM3/COM4，然后让emulator使用COM3，而串口分析工具则打开COM4，这样就可以实现emulator和分析工具间的通信了。这在实际工程项目中是非常有用的一种调试手段。

（2）经过上一步骤，我们成功启动了一个带串口的模拟器。接下来，还需要找出这个串口在/dev下的名称。按照Android模拟器的实现，它会在系统的/dev/ttySN串口设备编号上，为新增的串口分配一个名称（N表示有多个串口，依次递增）。

比如系统本身已有/dev/ttyS0、/dev/ttyS1，那么新加的串口就变成了/dev/ttyS2。

我们需要为这个串口设备设置权限，这样才能为后续的读写操作提供可能。命令如下：

```
#adb shell
# chomd 777 /dev/ttyS2
```

（3）到这一步，串口已经基本可用。读者可以写个应用程序来测试下，或者下载著名的开源项目serial-port-api 程序（http://code.google.com/p/android-serialport-api/）来进行测试。它的主界面如图25-3所示。

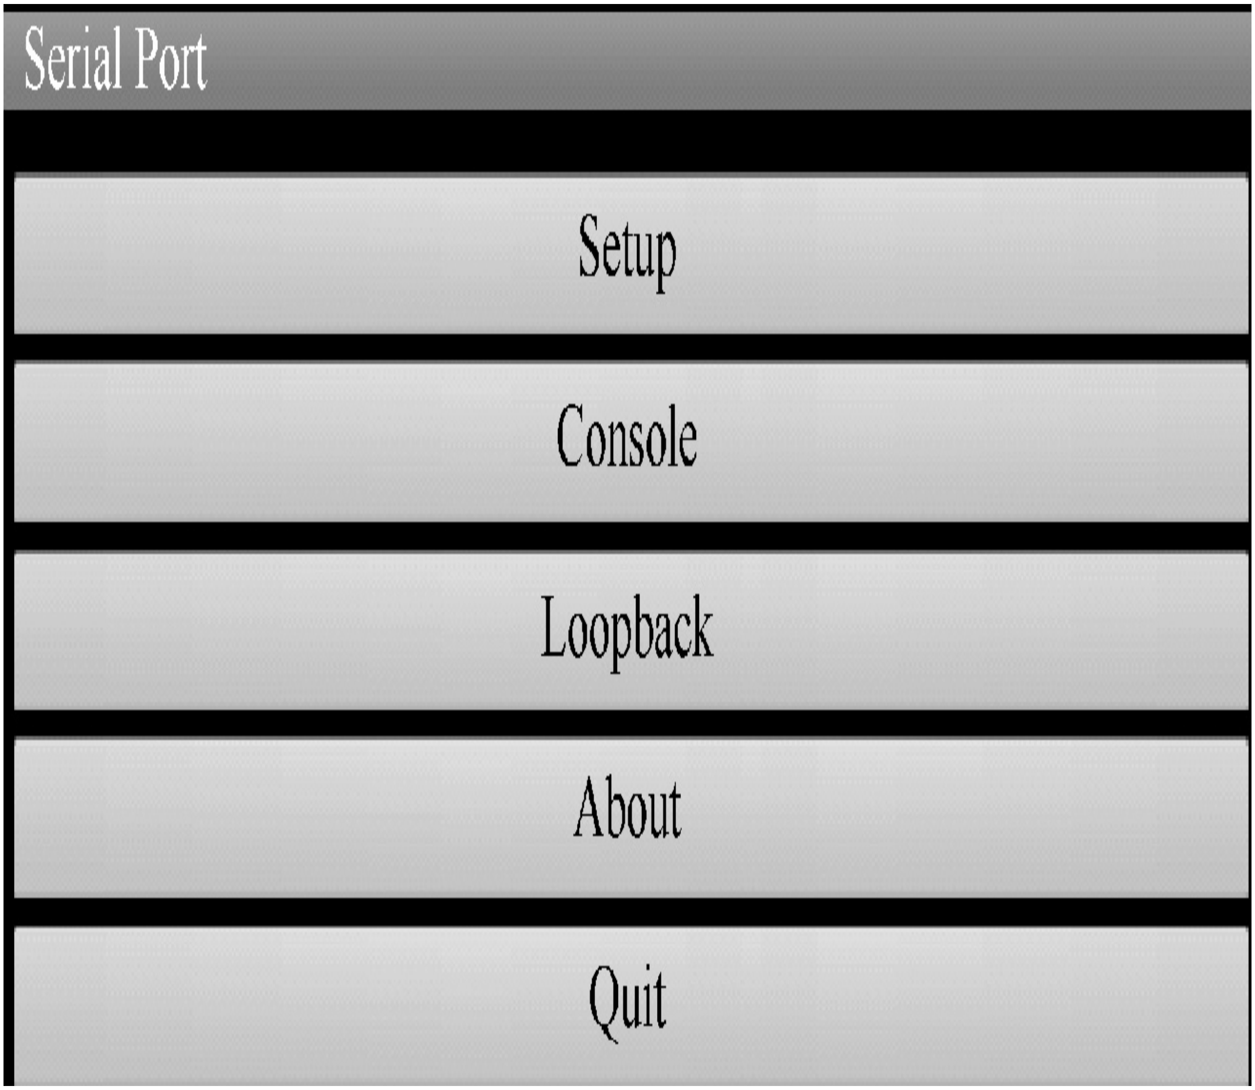

▲图25-3　主界面

这样我们就成功地在Android模拟器中添加了串口功能，并且经过测试验证和真实设备的串口操作没有任何区别。读者如果还有其他需求，也可以参照本节讲解的方法来尝试“改造”Android模拟器。

25.2 此Android非彼Android

这个工具取名为“Android”并不是很恰当，既会引起误解，也没有表达出工具本身的真正用途。它的主要功能有3个，即：

- 管理AVD（Android Virtual Devices）；
- 管理Android项目；
- 管理Android SDK平台、插件、文档等。

它是一个命令行程序，语法如下：

```
android [global options] action [action options]
```

如果是在Eclipse下开发，ADT本身已经集成了“Android”这个工具的功能，因此开发者一般情况下不需要直接通过命令行的形式来操作。

我们来看看它的常见用法。

（1）全局选项如表25-16所示。

表25-16　全局选项

选项	说　明
-s	silent模式，这时只有error才会输出
-h	显示帮助
-v	Verbose模式，即无论error，warning或者information信息都会输出

（2）管理AVD和SDK如表25-17所示。

表25-17　管理AVD和SDK

动作	选　　项	说　　明
avd		启动AVD管理器
sdk		启动SDK管理器
create avd	-n <name>	AVD的名称
create avd	-t <targetID>	使用ID为targetID的系统映像文件。获取可用的ID列表，可以用“android list targets”。一般的列表格式如下： id: 1 or "android-3" Name: Android 1.5 Type: Platform API level: 3 Revision: 4 Skins: HVGA (default)、HVGA-L、HVGA-P、QVGA-L、QVGA-P ABIs : armeabi
	-c <path>|<size>[K|M]	设置SD卡的映像文件或者新建一个容量为size的SD卡
	-f	强制生成AVD
	-p <path>	此AVD相关文件的存放路径
	-s <name>|<width>-<height>	此AVD使用的皮肤文件
delete avd	-n <name>	删除指定的AVD
move avd	-n <name>	需要移动的AVD名称
	-p <path>	目标路径
	-r <new-name>	为AVD重新命名

update avd	-n <name>	更新AVD

（3）管理项目如表25-18所示。

表25-18　管理项目

动　　作	选　　项	说　　明
create project	-n <name>	新建项目名
	-t <targetID>	同“create avd”一样
	-a	默认的Activity名
	-p <path>	项目路径
update project	-n <name>	需要更新的项目名称
	-p <path>	项目路径
	-l <library path>	需要添加的库的存放路径
	-s <subprojects>	更新子目录下的项目
	-t <targetID>	同创建时的选项

create-test-project	-n <name>	创建测试项目
	-p <path>	项目路径
	-m <main>	项目名称
update-test-project	-p <path>	测试项目的路径
	-m <main>	需要测试的“主类”
create-lib-project	-k <packageName>	新建的库项目的包名
	-p <path>	项目路径
	-t <targetID>	同前面的描述
	-n <name>	项目名称
update-lib-project	-p <path>	库项目的路径
	-l <libraryPath>	需要添加的库的存放路径
	-t <name>	同之前的targetID描述

（4）为AVD添加硬件支持。

在开发某些应用程序时，我们可能需要特定硬件设备的支持。以下列表给出了AVD所有支持的硬件属性，开发者可以在AVD目录下的config.ini文件中添加相应属性的赋值语句如表25-19所示。

表25-19　AVD目录下的config.ini文件中添加相应属性

硬 件 支 持	属　　性	描　　述
内存	hw.ramSize	物理内存大小，默认值为96M
触摸屏	hw.touchScreen	是否需要触摸屏，默认值为“yes”
轨迹球	hw.trackBall	是否有轨迹球，默认值为“yes”
键盘	hw.keyboard	是否有QWERTY键盘，默认值为“yes”
DPad（Directional pad）通常用于游戏控	hw.dPad	是否有DPAD，默认值

制		为“yes”
GSM modem	hw.gsmModem	是否有GSM Modem，默认值为“yes”
摄像头	hw.camera	是否有摄像头，默认值为“no”
摄像头水平方向最大像素	hw.camera.maxHorizontalPixels	默认值为“640”
摄像头垂直方向最大像素	hw.camera.maxVerticalPixels	默认值为“480”
GPS	hw.gps	是否有GPS，默认值为“yes”
电池	hw.battery	是否有电池，默认值为“yes”
		是否有加

加速器	hw.accelerometer	速器，默认值为“yes”
音频录制	hw.audioInput	是否有音频录制设备，默认值为“yes”
音频回放	hw.audioOutput	是否有音频回放设备，默认值为“yes”
SD卡	hw.sdCard	是否有SD卡支持，默认值为“yes”
Cache分区	disk.cachePartition	是否使用/cache分区支持，默认值为“yes”
Cache分区大小	disk.cachePartition.size	/cache分区的默认值为“66MB”
LCD屏密度		AVD屏幕

（density）	hw.lcd.density	的默认密度为“160”

25.3　快速建立与模拟器或真机的通信渠道——ADB

ADB（Android Debug Bridge）可以让研发人员快速建立与模拟器或真机的通信渠道。正如其名称所表示的，它是一座调试的桥梁——并且基于命令行格式。

25.3.1　ADB的使用方法

对于一般的开发者而言，ADB是一个可执行程序，位于SDK安装路径下的platform-tools目录中。它的安装也非常简单——用户只要下载Android的SDK即可。当然，如果希望在任何地方都可以调用到ADB，那么可以考虑将它的存储路径加入系统Path中。

如果是在Eclipse开发环境下，甚至不用直接接触到具体的ADB命令。因为Android的ADT工具已经内部集成了对ADB的调用。比如只需要在Eclipse下通过单击工程右键，然后选择“Run as-> Android Application”来将应用程序安装到指定的目标设备中，而不必亲自调用ADB的“应用程序安装命令”。

接下来我们介绍ADB中常用的一些命令，通用格式如下所示：

```
adb[-d|-e|-s <serialNumber>]<command>
```

因为ADB是一种多对多的架构（多个ADB Client以及多个目标设备，下一小节有详细讲解），所以在使用ADB命令时，需要特别指定我们所针对的目标对象。如果不清楚设备对应的“serialNumber”，可以先执行如下查询命令：

```
adb devices
```

这样就可以得到当前所有目标设备的状态了，如下所示。

```
C:\Documents and Settings\Administrator>adb devices
List of devices attached
emulator-5554   device
emulator-5556   device
```

以上格式是：

[serialNumber][state]

其中serialNumber又由“类型”和“端口号”组成，以“-”隔开；State则有两种状态，即：

- Offline. 说明当前设备没有连接或无响应。
- Device. 说明当前设备已经和ADB Server正常连接。

比如上面的例子中共展示了两个模拟器设备（emulator），端口号分别为5554和5556，而且都处于正常连接状态。

接下来就可以向指定设备发送ADB命令了。如下所示是我们通过ADB在emulator-5556上安装一个APK应用程序的命令。

```
C:\Documents and Settings\Administrator>adb -s emulator-5556 install C:\AutoTest
_Ex02_Calculator.apk
50 KB/s (42878 bytes in 0.828s)
        pkg: /data/local/tmp/AutoTest_Ex02_Calculator.apk
Success
```

表25-20是对ADB常用命令的释义，更多详情可以参见官方文档。

表25-20　ADB重要命令一览表

所属类型	命　　令	描　　述	说　　明
	-d	只将adb命令发送给唯一的USB连接设备	如果用USB连接的设备并不是唯一的，将会返回错误
	-e	只将adb命令发送给当前唯一运行的	如果当前运行的模拟器实例

Options		模拟器实例	超过一个，将会返回错误
	-s <serialNumber>	将adb命令发送给指定的模拟器/设备。比如前一个例子中指定在emulator-5556上安装了一个应用程序	如果没有指定，将会产生错误
General	devices	将显示当前所有连接的模拟器/设备	返回结果的格式我们在上面已经描述过了
	connect <host>[:<port>]	通过TCP/IP连接目标设备	host代表目标设备的IP地址，port是端口号。如果不指定port，默认采用5555端口
	disconnect [<host>[:<port>]]	断开与目标设备的TCP/IP连接	host代表目标设备的IP地址，port是端口号
	help	显示adb的帮助信息	
	version	显示adb的版本信息	
Debug	logcat [<option>] [<filter-specs>]	将log信息打印到屏幕上	
	bugreport	将dumpsys，dumpstate和logcat信息打印到屏幕上	
	jdwp	显示可用的JDWP进程列表	
	install <path-to-apk>	将指定路径下的应用程序安装到模拟器或者设备中。可	

		以参考上面的例子	
Data	pull <remote> <local>	将模拟器或设备上的指定文件复制到开发环境机器上（Adb Client 和Server所处的环境）	
	push <local> <remote>	将开发环境机器上的特定文件复制到模拟器或设备中	
Scripting	get-serialno	打印出模拟器/设备的serialno	
	get-state	打印出模拟器/设备的状态	
	wait-for-device	当设备不处于在线状态时，这个选项会暂停命令的执行，直到相应设备可用	参见表格后面的注解1
Server	start-server	这个命令用来检查adb server是否正在运行，如果没有，会将其启动	
	kill-server	这个命令会终止正在运行的adb server	
Shell	shell	这个命令用来启动一个shell环境	
	shell [<shellCommand>]	和上面不同的是，这个命令会直接执行用户指定的shell命令，结束后便会退出shell环境	

注解：这个选项通常放置在ADB命令前面，表示此命令会一直等待，直到其针对的目标设备处于可用状态。比如下面这个例子：

```
adb wait-for-device shell getprop
```

在使用这个选项时，有一点读者应该特别注意——对于那些需要在设备完全启动的状况下才能成功执行的adb命令，这个选项可能会不起作用。比如我们之前提到的安装应用程序的命令，如果系统在还没有启动完成前adb命令就开始执行，那么安装任务很可能会失败。

一般情况下，开发人员通过USB线将研发机（PC）与目标设备进行连接，然后就可以通过ADB向目标设备发送各种命令了。但这并不代表ADB只能通过USB连接——比如它也支持TCP/IP网络的互联方式。下面我们就举例说明如何通过WiFi来实现ADB的连接，如图25-4所示。

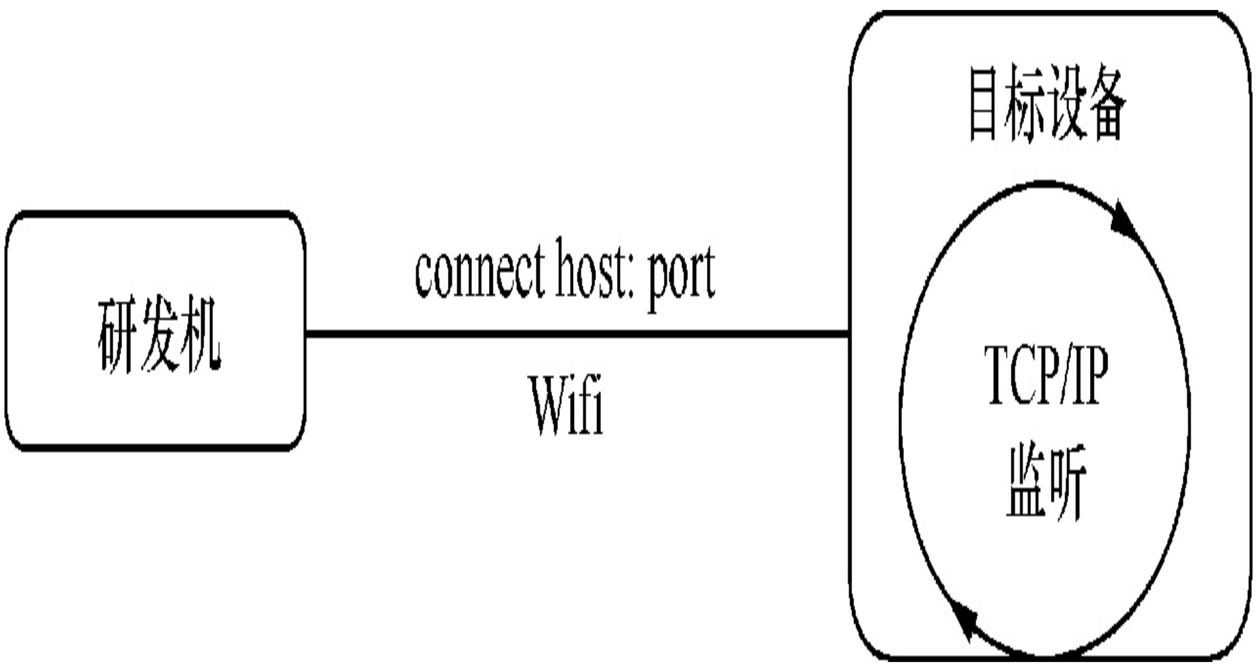

▲图25-4　通过Wi-Fi连接ADB

- 要实现研发机与目标设备的TCP/IP连接，首先要保证它们是可以通过网络互相访问的（一般情况下，需要两者处在同一个网络环境中，如局域网）。
- 将目标设备设置为TCP/IP监听状态。可以执行以下命令来完成这一设置（此时研发机与目标设备还是需要通过USB连接，否则无法发送ADB命令）：

```
adb tcpip <port>
```

命令中的port指定了目标设备将在哪个端口进行监听，因而后续的连接命令要和这里的端口设置保持一致才能成功。

- 拔除目标设备与研发机的USB连接，为下面的“无线连接”做准备。
- 此时目标设备已经在指定的端口进行监听（IP地址通常是由WiFi路由器自动分配的，我们不能指定）了，研发机可以通过如下命令与设备实现WiFi互联：

```
adb connect <host>[:<port>]
```

其中，host是目标机的ip地址，而port就是上面tcpip命令设置的监听端口。

- 通过以上几个步骤，研发机中的ADBServer和目标设备上的ADBD（见下面小节的分析）就实现了TCP/IP的连接。此时如果打开Eclipse中的DDMS，就可以发现目标机已经处于online状态。后续操作和USB连接时的情况没有任何差别。

25.3.2 ADB的组成元素

ADB虽然采用的是客户端/服务器模型，但与普通C/S模型有一个很大的区别，即它的框架中包含了3个重要组成部分。

- ADB Client

ADB客户端运行在研发机（PC）设备上。比如我们在Windows操作系统下的Eclipse中进行开发，那么ADB Client就运行在Windows环境中。

- ADB Server

和C/S模型中的理解不同，ADB的服务端程序和客户端一样，都运行于研发机设备上。这是因为ADB Server主要有两方面的任务。

其一，管理研发机设备与目标设备/模拟器的连接状态——这两者是“多对多”的关系，所以需要有一个“管理者”。

其二，处理ADB Client的连接请求。

- ADB Daemon

Daemon作为后台进程运行在目标设备/模拟器中。它将与ADB Server进行通信连接以完成一系列ADB的命令请求。

如图25-5所示。

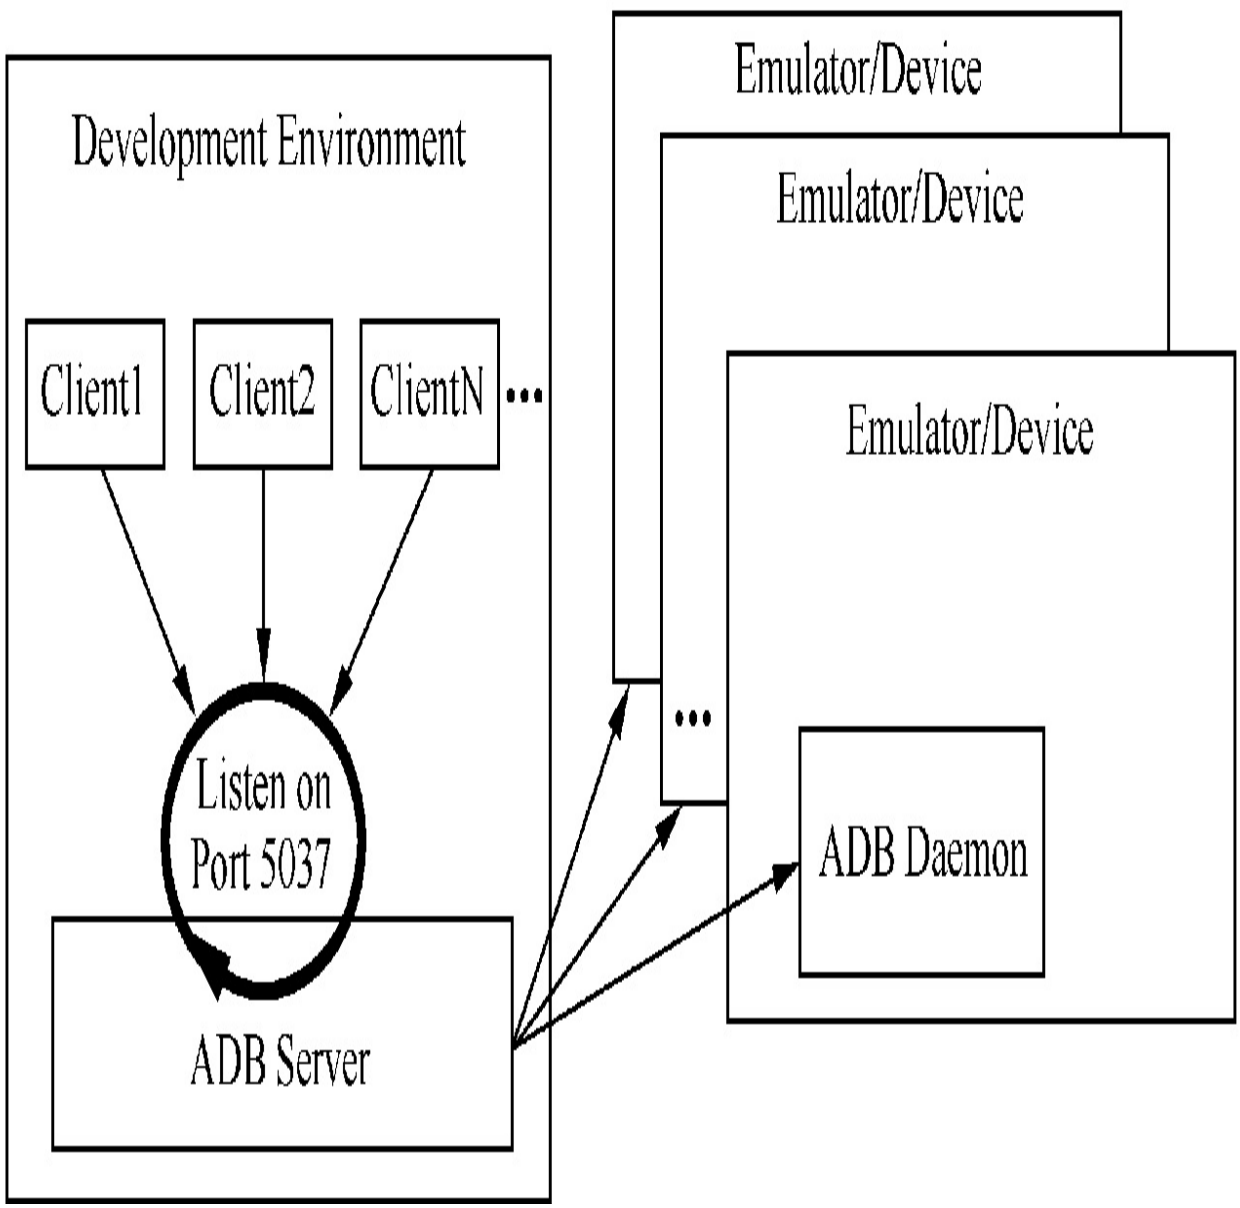

▲图25-5　ADB Client、Server和Daemon示意图

当用户需要发送ADB命令时，将首先启动一个ADB Client。随后ADB会检查Server程序是否已经在运行，否则它还会启动Server。ADB Server将绑定在TCP的5037端口上并开始等待客户端程序的连接。

另外，ADB Server也会主动扫描有效的模拟器/设备。扫描所用的端口范围是5555～5585的奇数号——读者可能会奇怪为什么只用到奇数号。这是因为每一个模拟器/设备都需要用到两个端口号，分别用于console和adb的连接。举个例子，如果一个emulator已经和ADB Server建立了连接，那么下一个emulator分配到的端口号就如表25-21所示。

表25-21　emulator分配到的端口号

端口号	用　　途
5556	console
5557	adb

这样就有效保证了多个目标设备的同时运行和管理。

25.3.3　ADB源代码解析

ADB源代码在Android工程目录下的/system/core/adb/中。从前面小节的分析中我们知道ADB是由3部分元素组成的，即ADB Client、Server和Daemon。但从源代码的角度来分析，ADB的设计者并没有将这3个元素的源文件单独分隔开来——而是采用了包括宏在内的巧妙方式来区分它们。这在一定程度上加大了我们阅读源代码的难度。为了更好地理解每一组成部分，读者可以先从ADB的makefile文件入手，了解各个模块所对应的源文件——对于ADB makefile的详细分析我们其实在本书基础篇中已经提前讲解了，不清楚的读者可以回头复习。

表25-22直接给出了各模块所对应的源文件。

表25-22　各模块所对应的源文件

模　块　名	源文件列表
ADB Host（ADB Client/ADB Server）	adb.c
	console.c
	transport.c
	transport_local.c
	transport_usb.c
	commandline.c
	adb_client.c
	adb_auth_host.c
	sockets.c
	services.c
	file_sync_client.c
	$(EXTRA_SRCS)，与操作系统环境有关
	$(USB_SRCS)，与操作系统环境有关
	utils.c
	usb_vendors.c
Adb Daemon	adb.c
	backup_service.c
	fdevent.c
	transport.c
	transport_local.c
	transport_usb.c
	sockets.c
	services.c
	file_sync_service.c
	jdwp_service.c
Adb Daemon	framebuffer_service.c
	remount_service.c
	usb_linux_client.c

	log_service.c
	utils.c

由表可知，3个组成元素在很大程度上复用了代码。

接下来我们以ADB的主函数为入口来分析其内部源码实现。

ADB Client，Server和Daemon的main函数都在adb.c中。源代码如下：

```
int main(int argc, char **argv)
{
#if ADB_HOST//通过这个宏来区分ADB Host和Daemon
    adb_sysdeps_init();
    adb_trace_init();
    D("Handling commandline()\n");
    return adb_commandline(argc - 1, argv + 1);
#else
    adb_qemu_trace_init();
    if((argc > 1) && (!strcmp(argv[1],"recovery"))) {
        adb_device_banner = "recovery";
        recovery_mode = 1;
    }
    start_device_log();
    D("Handling main()\n");
    return adb_main(0, DEFAULT_ADB_PORT);
#endif
}
```

从上面这段代码可以看出，ADB的主函数将通过ADB_HOST宏来判断当前程序是ADB Host或者ADB Daemon——这就意味着ADB_HOST在编译时会有所区别。对于ADB Host、makefile中加入了额外的编译选项。如下所示：

```
LOCAL_CFLAGS += -O2 -g -DADB_HOST=1  -Wall -Wno-unused-parameter
LOCAL_CFLAGS += -D_XOPEN_SOURCE -D_GNU_SOURCE
LOCAL_MODULE := adb
```

而对于ADB Daemon，这个宏定义发生了变化。

```
LOCAL_CFLAGS := -O2 -g -DADB_HOST=0 -Wall -Wno-unused-parameter
LOCAL_CFLAGS += -D_XOPEN_SOURCE -D_GNU_SOURCE
```

可见当ADB_HOST为1时，代表ADB Host；否则为0时，表示ADB Daemon。以下两个小节我们将分别分析在这个宏区分下的ADB Host和ADB Daemon。

1．ADB Host源码解析

本小节我们选择一条具体的ADB命令来完整解析它的实现过程——同时也是本书自动化测试篇中将会用到的一个重要命令。如下所示：

```
$ adb shell am instrument com.ThinkingInAndroid.AutoTest/android.
```

（1）ADB命令的典型处理流程。

上述的ADB命令用于启动Android的InstrumentationTestRunner，并承载如下测试包的运行：

```
com.ThinkingInAndroid.AutoTest
```

其流程如图25-6所示。

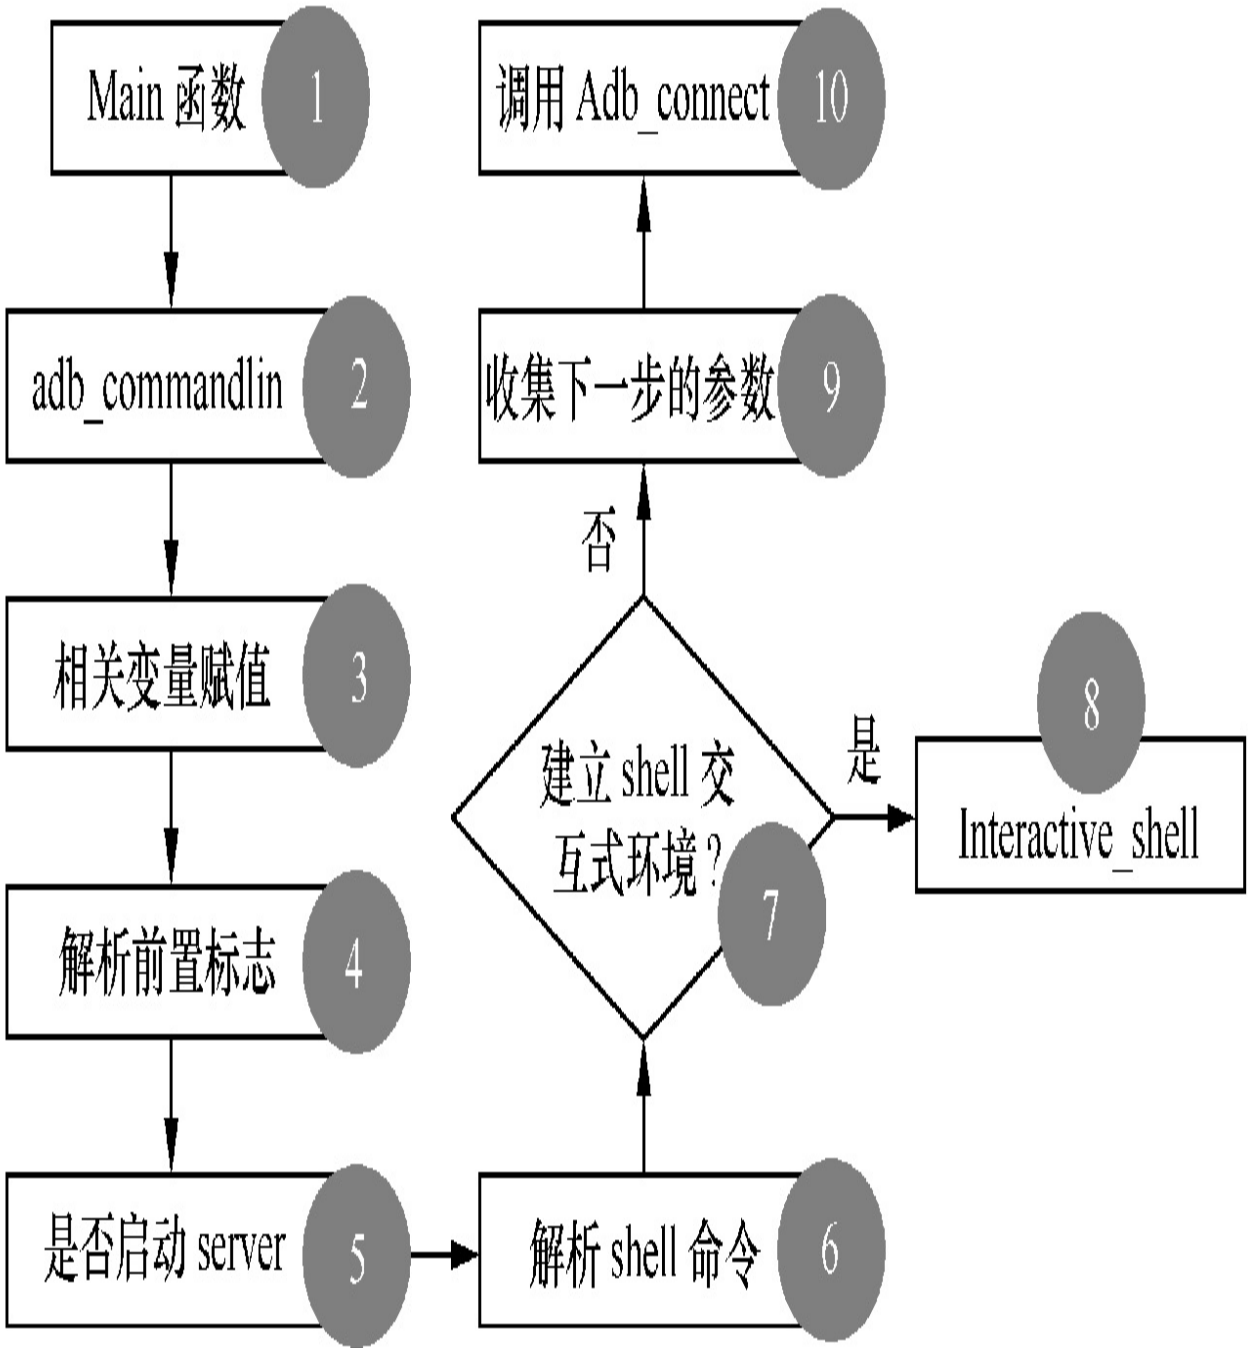

▲图25-6　流程图

① 关于main函数我们前一个小节已经做过分析了。

② 如果是ADB Host，那么main函数将会调用adb_commandline来解析用户要求执行的命令。也就是说，ADB Host与用户的交互接口就是一条条命令。

③ 在adb_commandline函数中，首先会对一些重要变量进行赋值，如ADB Server的端口号，便是在这里通过读取环境变量ANDROID_ADB_SERVER_PORT得到的。

④ 前置标志为当前命令的运行提供了限定条件，如我们之前所看到的-d，-e将在这一步进行解析。另外，到目前为止我们只知道可以通过ADB_HOST来区分Host和Daemon，而Host中其实同时包含了Client和Server，它们又是如何区别的呢？

事实上，ADB Server是由程序自动启动的——即如果主函数的argv[0]中带有“server”或者“fork-server”参数（这是ADB Client用于孵化ADB Server的特殊标志），那么变量is_daemon将被置1——这将在下一个步骤中产生影响。

⑤ 根据上述的参数解析结果，程序会判断是否要启动ADB Server：如果是最终调用launch_server。后者则负责启动Server，关键语句（Windows操作系统中）如下：

```
ret = CreateProcess(program_path, /* program path  */
        "adb fork-server server",/* the fork-server argument 
                                 debug = 2 in the child*/
        NULL, /* process handle is not inheritable */
        NULL, /* thread handle is not inheritable */
        TRUE, /* yes, inherit some handles */
        DETACHED_PROCESS, /* the new process doesn't have a c
        NULL, /* use parent's environment block */
        NULL, /* use parent's starting directory */
        &startup, /* startup info, i.e. std handles */
        &pinfo );
```

读者可以自行理解函数各参数的含义，然后体会下这种设计的巧妙之处。

⑥ 到了这一步，才真正开始处理我们的“shell”请求——后面的几个步骤都是围绕这个请求展开的。

⑦ 如果用户的命令是"adb shell"，即不带任何参数的情况，那么将启动一个交互式的shell环境。如下所示：

```
C:\Documents and Settings\Administrator>adb shell
root@generic:/ #
```

否则程序会直接执行用户指定的shell指令，而不提供交互环境。比如这个例子中，对应的shell指令是：

"am instrument com.ThinkingInAndroid.AutoTest/android.test.InstrumentationTest
么当指令完成以后，ADB将自动退出shell环境。

⑧ 这一步就是创建交互式shell环境的地方，在这个例子中不会执行到。

⑨ 在连接ADB Server之前，程序会对“已经处理过”和“未处理”的参数进行整理。另外，为了把这几个参数合并为一个有效的字符串，参数中包含空格的地方还需要加上引号。

⑩ 将上一步得到的参数传入adb_connect——这个函数要处理的事情比较多，我们接下来专门进行讨论。

（2）函数adb_connect的处理流程。

图25-7描述了adb_connect的整体调用流程。

① adb_connect函数开始执行。

② 先查询当前ADB Server的版本号。目的有两个，即获知当前是否有Server在运行，以及它的版本号是否符合要求（见下面第4步）。

③ 对上一步的结果进行判断。

④ 如果成功查询到当前Server的版本，说明ADB Server已经启动。这时还应进一步检查它的版本号是否符合要求。

⑤ 如果当前正在运行的ADB Server版本不符合要求，将会被系统强行结束并重新启动。流程和下面的第6步是一样的，因此在代码实现中直接用goto语句进行了跳转。如果ADB Server的版本号也通过了检查，那么程序将直接进入第7步。

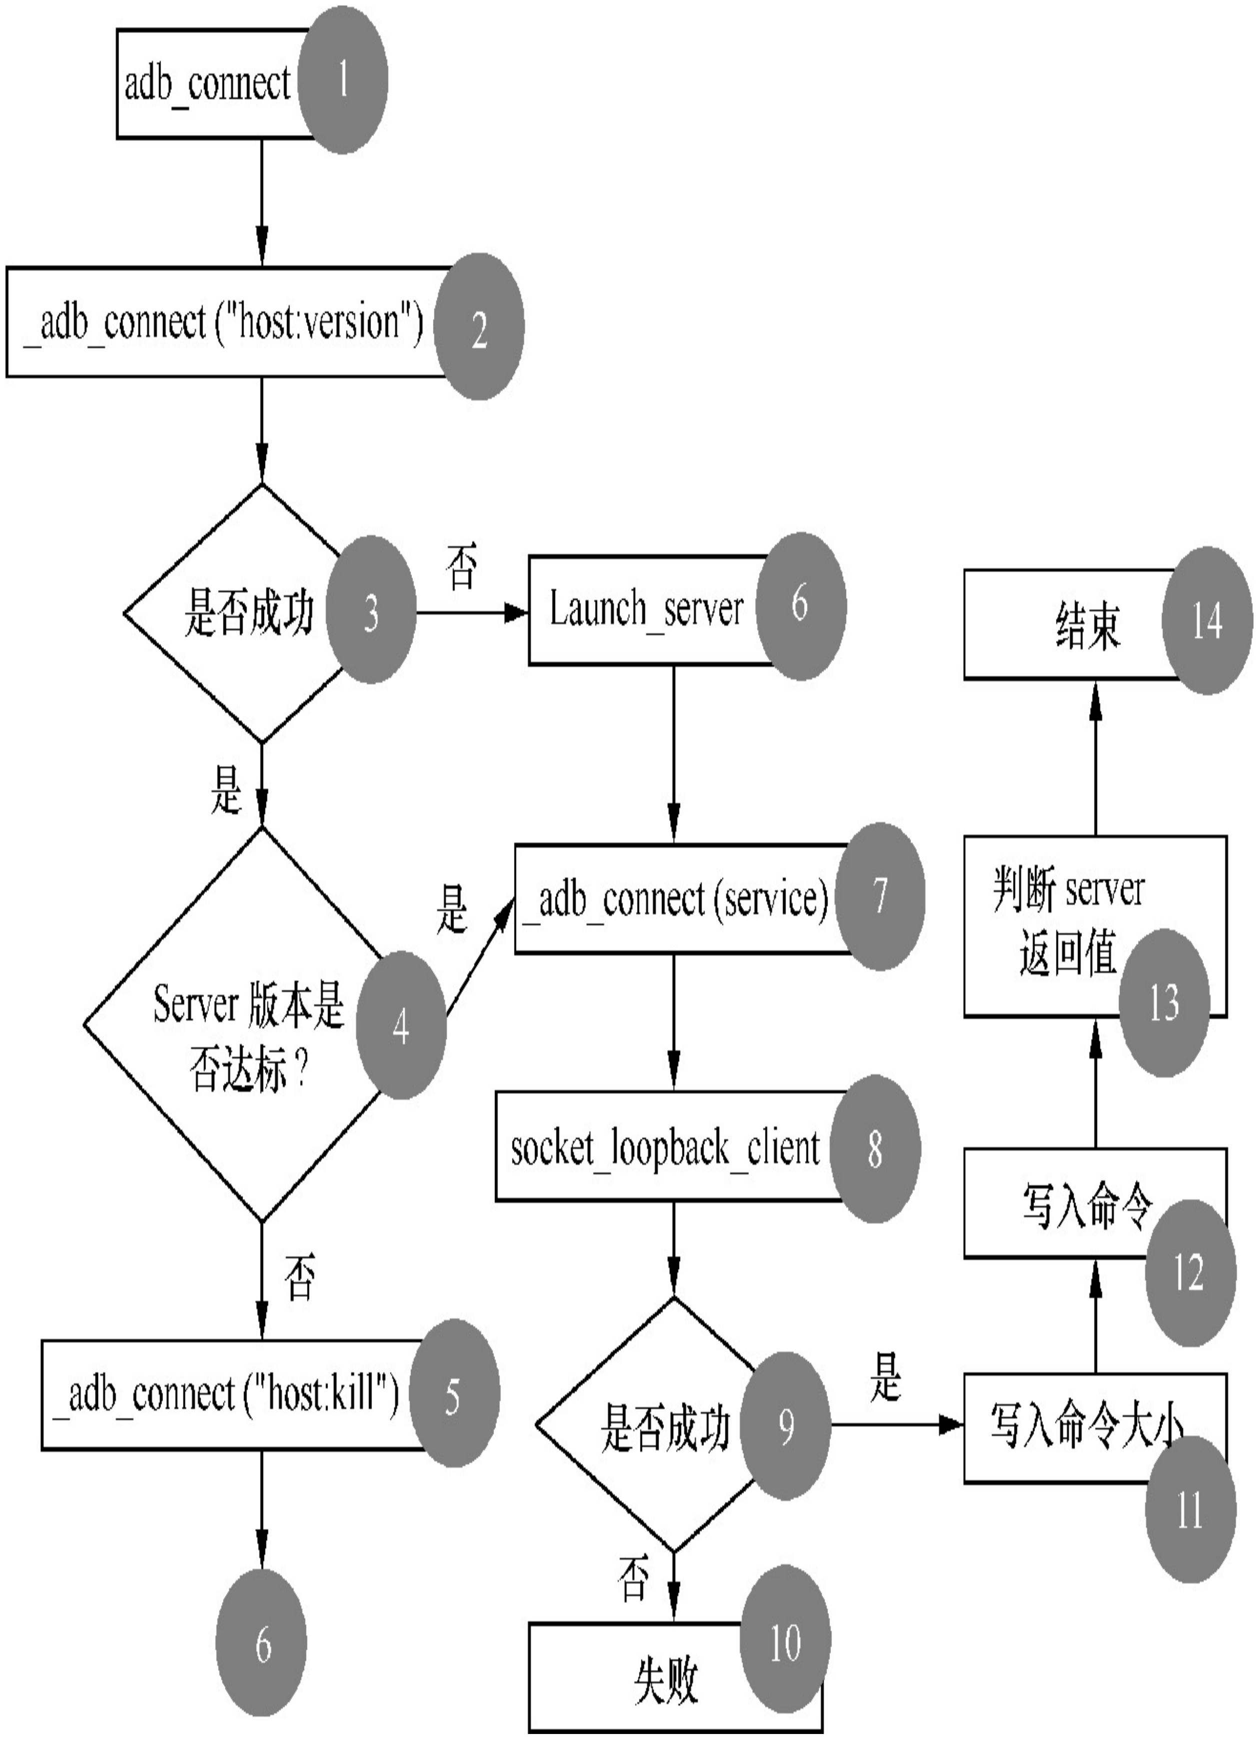
adb_connect
1
_adb_connect ("host:version")
2
是否成功
3
否
Launch_server
6
是
Server 版本是否达标？
4
是
_adb_connect (service)
7
否
_adb_connect ("host:kill")
5
6
socket_loopback_client
8
是否成功
9
是
否
失败
10
写入命令大小
11
写入命令
12
判断 server 返回值
13
结束
14

▲图25-7　adb_connect的整体调用流程图

⑥ 启动一个ADB Server。不同操作系统环境下的实现略有差异，所以源码中使用了宏来进行区别控制。我们以Linux环境为例来简述下。

- 建立一个通道，这样父子进程才能进行通信。
- Fork一个新进程。我们知道，通过Linux的fork接口“孵出”的新进程程序执行点和原先进程完全一样。因此代码中需要通过判断进程号来区分父子进程——当pid为0时，代表当前是子进程；否则便是父进程。如果读者对这些基础知识不是很熟悉，建议查阅Linux相关资料。

相关源码实现如下：

```
if (pid == 0) {//Child进程(也就是被fork出来的ADB Server所在进程)
    adb_close(fd[0]);
    dup2(fd[1], STDERR_FILENO);
    adb_close(fd[1]);
    char str_port[30];
    snprintf(str_port, sizeof(str_port), "%d",  server_port);
    int result = execl(path, "adb", "-P", str_port, "fork-ser
    fprintf(stderr, "OOPS! execl returned %d, errno: %d\n", r
} else  {//Parent进程，也就是ADB Client所在进程
   …
```

ADB Server运行于子进程中。因此上述代码段中pid为0的分支，又调用了execl来真正加载Server程序；同时读者会发现它其实还是复用了adb的程序主体，只是函数参数变成了“fork-server”和“server”。我们在前面已经讲解过这两个特殊标志的含义，它们将在adb_commandline中被用于判断当前是否为Server进程。

对于ADB中代码的高度复用，我们可以打一个比方——ADB程序就像一把“瑞士军刀”，无论用户希望使用的是小刀、叉子甚至圆珠笔、镊子等，都只需通过传入相应的参数来轻松得到。

⑦ 一旦ADB Server启动后，ADB Client就可以开始连接它了。

⑧ socket_loopback_client(__adb_server_port,

SOCK_STREAM)。这里会尝试连接127.0.0.1本机地址的ADB Server端口。即向ADB Server发起连接请求。

⑨ 判断和ADB Server的连接是否已经成功。

⑩ 未能成功连接ADB Server，任务失败。

⑪ 如果和ADB Server连接成功，我们就可以向其发送数据了——要特别注意首先需要发送的是命令数据的字节数，然后才是命令数据本身。

⑫ 如果传送命令大小成功，这里将接着传输命令数据。在本例中，对应的是"shell:am instrument com.ThinkingInAndroid.AutoTest/android.test.InstrumentationTest

⑬ 完成上两步操作后，就可以通过Server 的返回值来判断命令是否执行成功。实际工作由Adb_status完成——当Server返回值为"OKAY"时，表示成功；返回值为"FAIL"时，表示失败。

⑭ 流程结束。

2. ADB Daemon

我们知道adbd程序运行于目标设备端（模拟器或真实设备），那么它是在什么情况下启动的呢？

先来看看init.rc中关于adbd的描述：

```
# adbd is controlled via property triggers in init.<platform>.usb
service adbd /sbin/adbd
    class core
    socket adbd stream 660 system system
disabled
    seclabel u:r:adbd:s0

# adbd on at boot in emulator模拟器的情况下
on property:ro.kernel.qemu=1
    start adbd
```

可见根据当前是模拟器或者真实设备，启动adbd的条件有所区别。本书的原理篇中对init.rc的语法规则有详细分析——如果读者对语法

还不是很清楚，可以先回头阅读再来分析上述这段内容。

“Service”说明adbd是一种可执行的服务程序，其存储路径在文件系统中的/sbin/adbd。后面紧跟的disabled选项告诉系统，不要在这里直接启动它——init.rc文件的其他地方会去显示调用这个服务。

如果是模拟器的情况下（即property:ro.kernel.qemu=1），那么将直接start adbd。

另外，ADB Daemon与前一小节ADB Host的内部源码结构类似，有兴趣的读者可以自行研究。我们将在下一小节中重点讲解Daemon和Host间的通信协议。

25.3.4 ADB Protocol

Protocol是事物之间沟通的桥梁。无论是在工程技术领域还是日常生活中，无时无刻都充满了协议的束缚——有的是人为强制规定的，如3GPP组织给出的全球性的通信协议；有的则是约定俗成的，如顾客在超市买东西，都是先付款后才能把货物带走，这就是顾客与店家的隐含协议。

ADB程序本身并不复杂，但“麻雀虽小，五脏俱全”，所以它也加入了严格的协议规范。具体而言分为两部分，即：

- ADB Client与ADB Server间的通信协议；
- 以及ADB Server与ADB Daemon间的通信协议。

下面我们逐一讲解。

1．ADB Client <- -> ADB Server

ADB协议的初衷就是让Server能响应Client的各种请求，而Client也能正确识别请求的执行结果。

从Client的角度来看，它向Server发送请求的流程如图25-8所示。

- ADB Client 需要先通过本机IP地址（127.0.0.1）的5037端口（注意：ADB Server的默认监听端口是5037，不过用户也可以通过设置

ANDROID_ADB_SERVER_PORT来做自定义），来与ADB Server建立连接。

- 连接成功后，首先发送数据的大小（用4个字节表示，并且为十六进制）。比如我们希望通过“host:version”来查询版本号，那么它的数据大小就是“000C”。
- 传送真正的数据内容，如上一步所说的“host:version”。

对于Server来说，它响应Client的过程如图25-9所示。

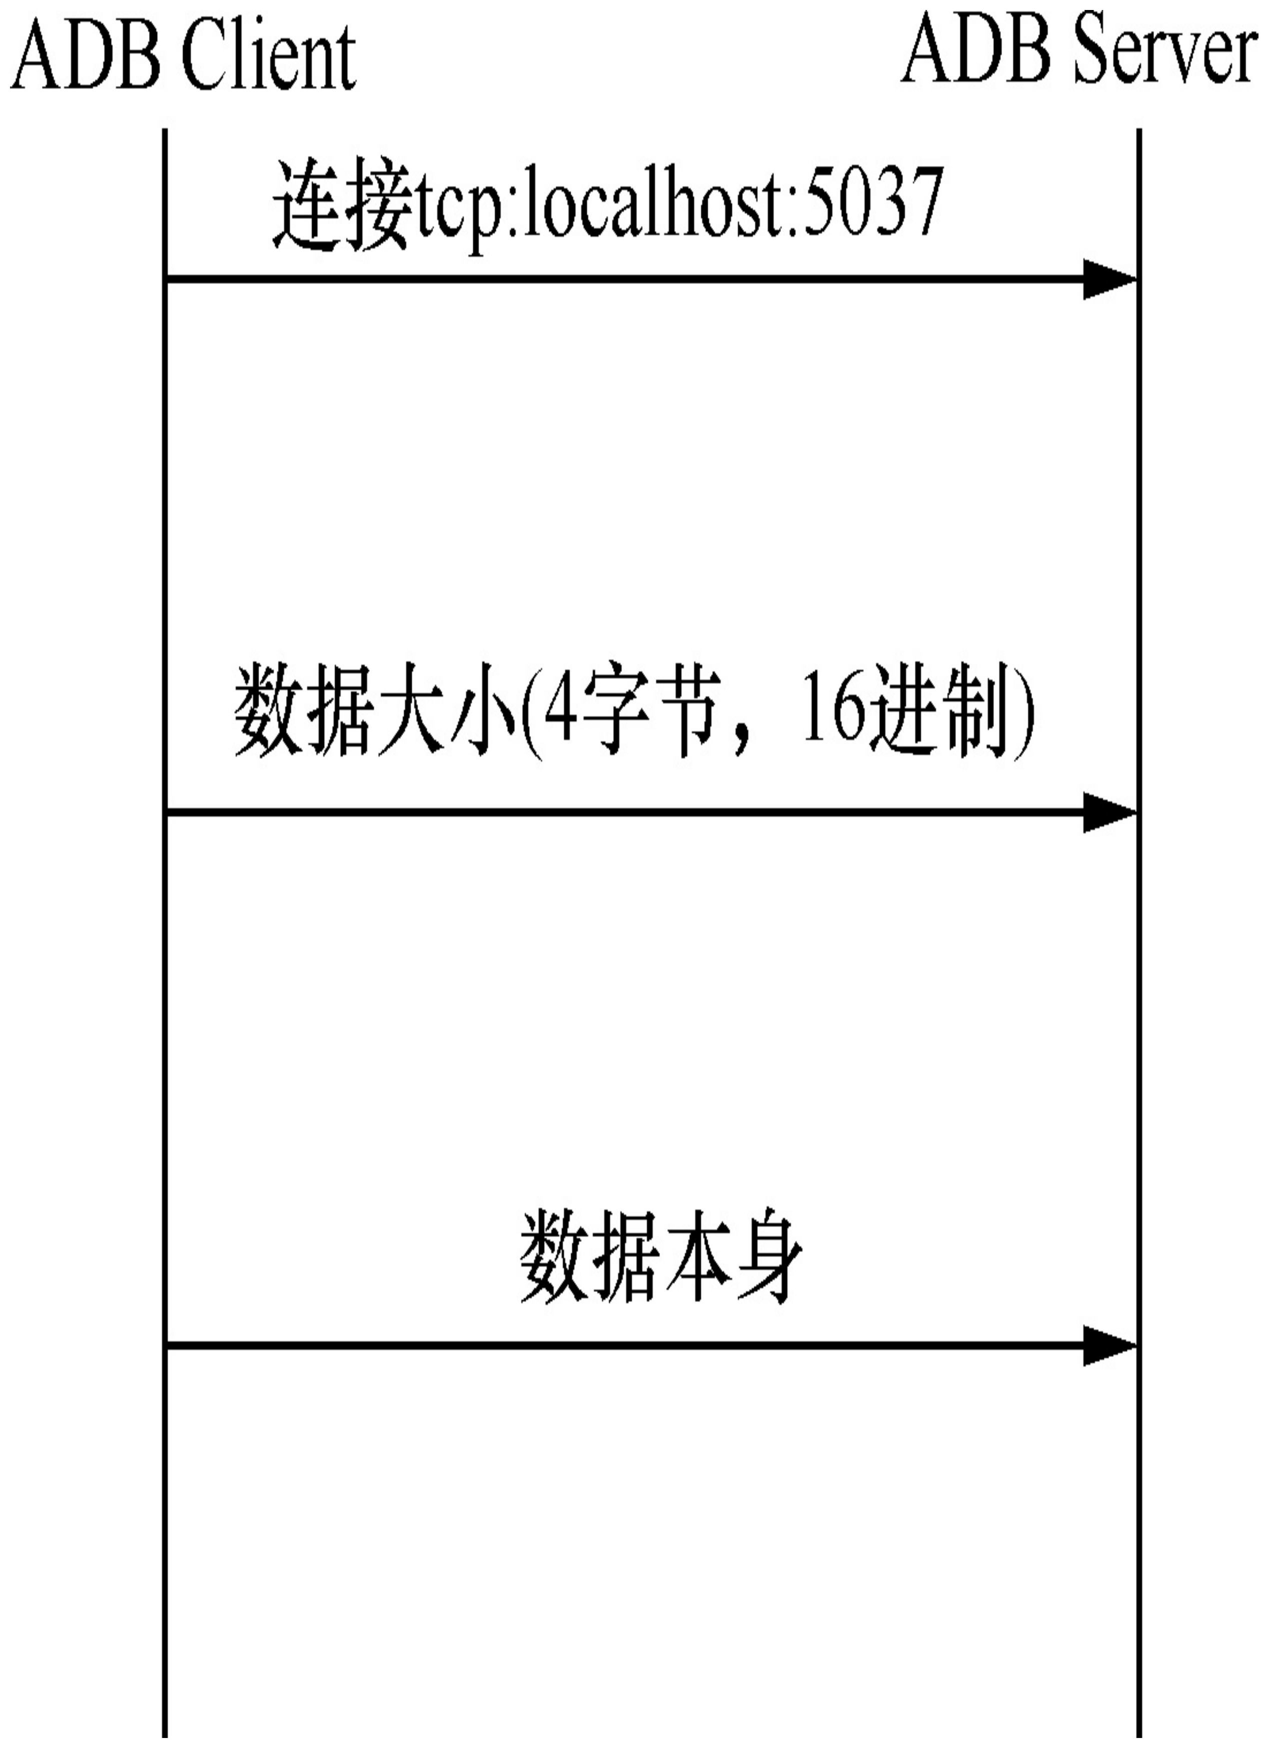
ADB Client
ADB Server
连接tcp:localhost:5037
数据大小(4字节，16进制)
数据本身

▲图25-8　ADB Client 向Server发起请求

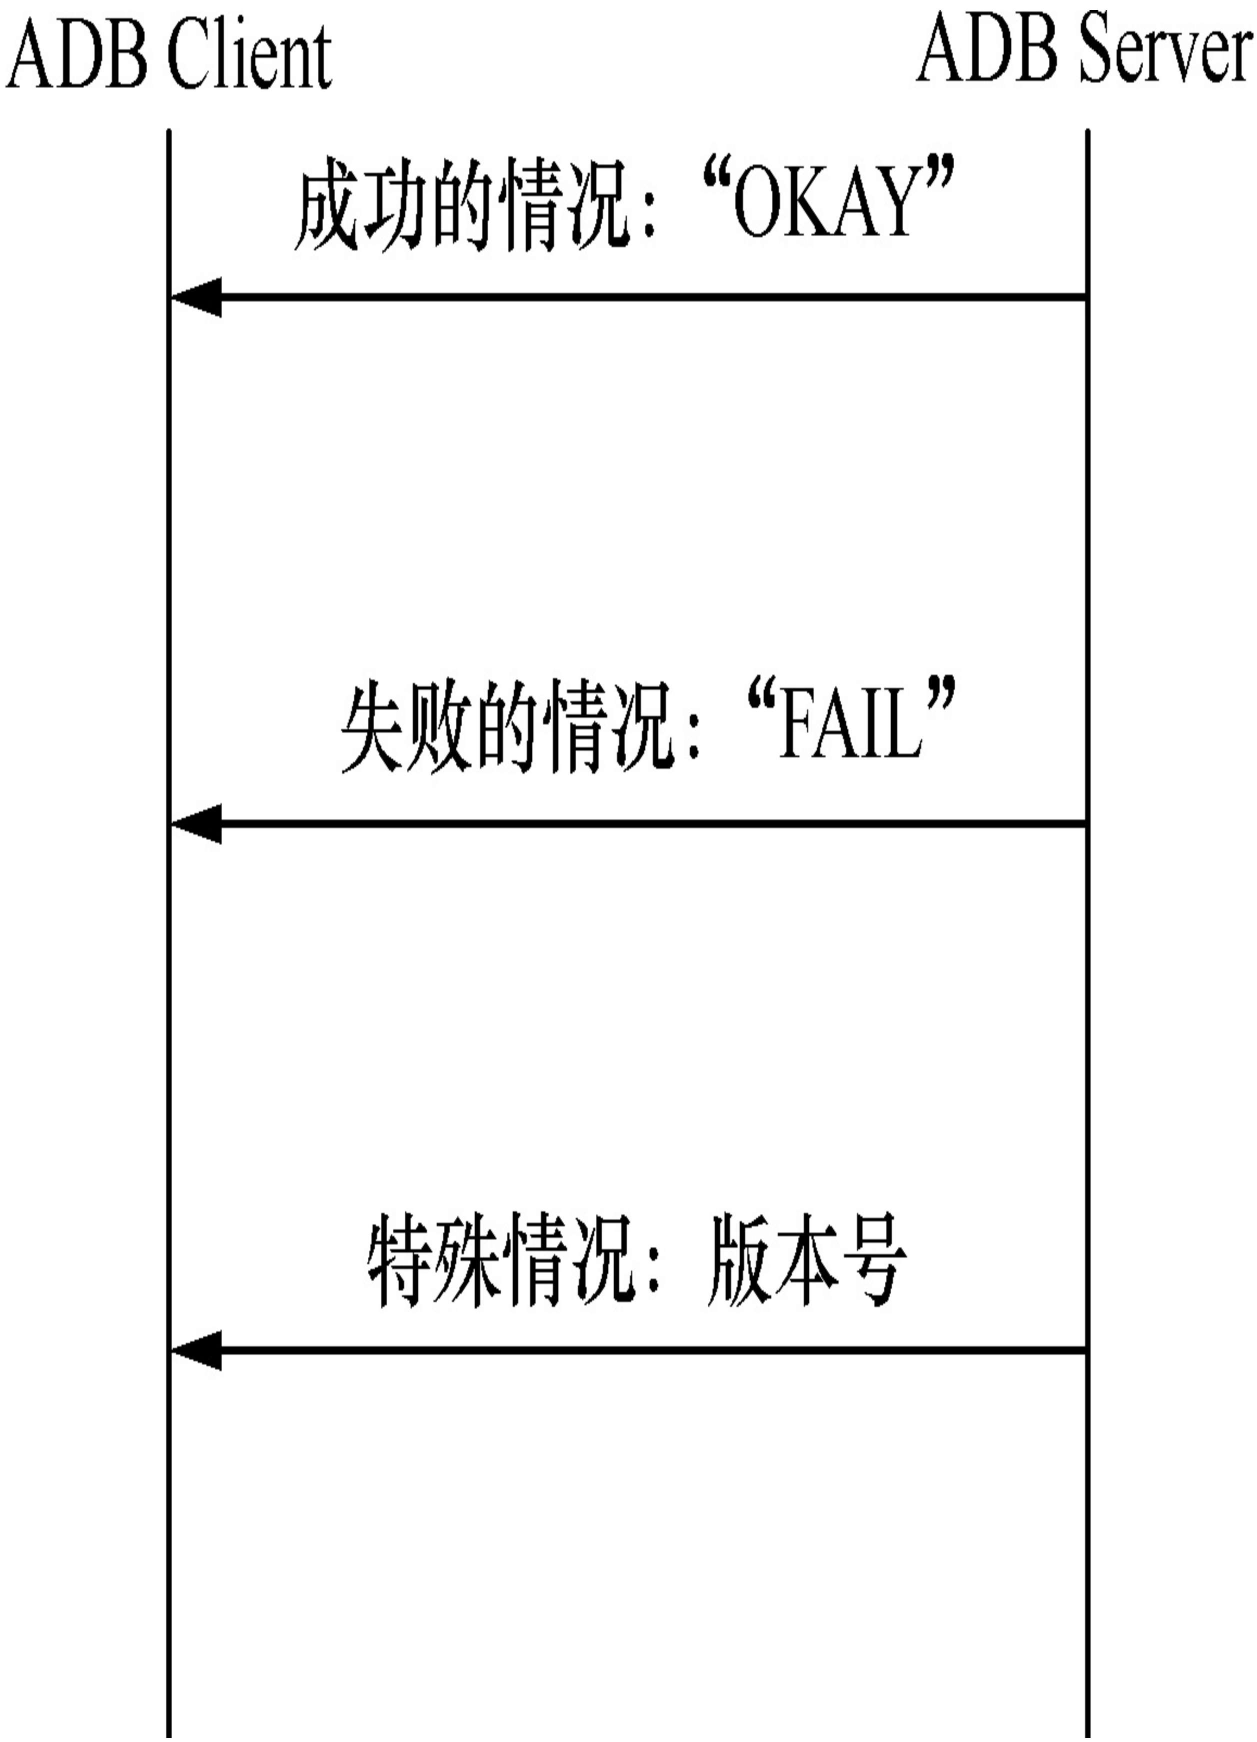
ADB Client
ADB Server
成功的情况：“OKAY”
失败的情况：“FAIL”
特殊情况：版本号

▲图25-9　ADB Server响应ADB Client的请求

- 如果请求被成功执行，Server将向ADB Client返回“OKAY”。
- 否则当有错误发生时，ADB Client将收到ADB Server发送的“FAIL”。
- 有一个特殊的情况，就是当我们查询版本号时，Server将直接返回一个4字节、十六进制的数值来表示版本号。

ADB Client和Server间目前支持的协议请求并不多，我们在表25-23中做统一解释。

表25-23　ADB Client与Server间的协议释义

Service类别	请　　求	说　　明
	host:version	向ADB Server查询内部版本号。在这种情况下Server不会给出OKAY或者FAIL的答复，而是直接返回一个4字节、十六进制表示的版本号
	host:kill	请求ADB Server程序退出。这通常是因为Client检测到当前正在运行的Server不符合要求，因此强制要求其退出（比如Server的版本号过老，就可能发生这种情况）
		向ADB Server查询当前可用的Android设备列表以及它们的状态。ADB Server首先会回应查询是否成功（OKAY或者FAIL）。在OKAY的情况下，随后将发送一个4字节、十六进制的数据大小说明，最后才是具体的数

	host:devices	据。ADB Client收到后进行解析得到设备的状态列表。 值得一提的是，当列表传输结束后，ADB Client和Server间的连接将会终止。这和下面的命令有本质的区别
	host:track-devices	这个命令是host:devices的升级版。它们完成的功能是一样的，区别在于host:track- devices在传送完列表后，并不终止客户与服务端的连接。 这就意味着当这些设备有变动时（添加、删除等），Server会主动发送通知给ADB Client，而不需要客户端不断发送查询才能实时跟踪到设备状态
	host:emulator:<port>	这个查询比较特殊，它是在有新的模拟器启动时，发送给ADB Server的，这样Server就可以知道一个新的模拟器实例启动了
	host:transport:<serial-number>	这个命令用来实现我们之前提到的-s选项。<serial-number>用来区分各Android设备，当用-s指定某个特定设备后，其后的命令都将发送到运行于此设备之上的ADB Daemon上
Host Service（Host Service，是指ADB Server自身	host:transport-	这个命令用来实现-d选项，将数据发送到通过USB连接的设备上。如果

就可以成功响应，而不需要与具体的Android设备进行沟通的那部分请求）	usb	当前有多个符合条件的设备，命令将失败
	host:transport-local	这个命令用来实现-e选项，将数据发送到通过TCP连接的模拟器上。如果当前有多个符合条件的模拟器，命令将失败
	host:transport-any	当没有指定-s、-d、-e中的任何一个选项时，将默认按这种情况处理——即发送给任何可用的设备/模拟器，不过如果有多个符合条件的设备/模拟器，将会失败
	host-serial:<serial-number>:<request>	这个命令表示Client要求ADB Server针对某指定的（serial-number）设备进行查询
	host-usb:<request>	这个命令是host-serial的变种，表示请求的目标是当前唯一通过USB进行连接的设备。如果USB连接的设备不存在或有多个，这个命令将失败
	host-local:<request>	这个命令也是host-serial的变种，表示请求的目标是当前唯一的模拟器实例。假如没有符合要求的模拟器，或者有多个实例存在，命令都将失败
	host:<request>	此命令告诉ADB Server，将请求发送给任何可用的模拟器或设备
	<host-prefix>:get-	返回对应设备或模拟器的serial number，格式型

	serialno	如“emulator-5554”，可以参考我们之前的描述
	<host-prefix>:get-state	以字符串形式返回指定设备的状态
	<host-prefix>:forward:<local>:<remote>	请求ADB Server将local的连接转为remote所指定的地址。其中，<host-prefix>可以是host-serial/host-usb/host-local/host中的任何一个 <Local>的格式有： ● tcp:<port> 如果是TCP连接的情况 ● local:<path> 如果是Unix Local Domain Socket的情况 <Remote>的格式有： ● tcp:<port> 如果是TCP连接的情况 ● local:<path> 如果是Unix Local Domain Socket的情况 ● jdwp:<pid> 如果是JDWP 线程的情况
	shell:command arg1 arg2 ...	在设备的shell环境下运行command命令，并返回结果或者错误描述。其后的arg1，arg2需要以空格隔开。 注意：如果某个参数的内容中包含有空格，需要用引号将此参数组织起来。这个命令和下面所描述的命令类似
		这个命令用来实现“adb shell”。和上面的区别在

	shell:	于，它会启动一个交互式的shell环境来承载用户的下一步操作
	remount:	请求adbd以“可读可写”的模式重新挂载设备文件系统，而不是只读。在做“adb sync”或者“adb push”前执行这个命令是有必要的。不过要注意在某些版本中这个命令是无效的
	dev:<path>	打开设备中的文件，以便于ADB Client进行读/写操作。这个命令通常用于调试，不过因为权限问题，并不是所有设备都支持。其中<path>参数是从设备的文件系统根目录开始的全路径
	tcp:<port>	尝试连接本机上的tcp <port>端口
	tcp:<port>:<server-name>	尝试去连接<server-name>机器上的tcp <port>端口
	local:<path>	尝试连接Unix Domain Socket
	localreserved:<path> localabstract:<path> localfilesystem:<path>	这些命令是上面local:<path>的变种，通常用于其他Android系统支持的Socket命名空间
	log:<name>	用于实现“adb logcat”。它用于打开一个系统的log（dev/log/<name>）并允许Client进行读取，权限

		是只读

Local Service	framebuffer:	这个命令用于获取屏幕截屏并将数据回传给Client。
		当ADB Server响应了“OKAY”以后，它会接着传送一个16字节的结构体，定义如下：
		{
		uint32_tdepth; //framebuffer的深度
		uint32_tsize; //framebuffer的大小（字节表示）
		uint32_t width; //framebuffer宽
		uint32_theight; //framebuffer高
		}
		在当前的实现中，深度是16，大小为宽*高*2。
		这个命令需要特殊的权限支持才能完成

	recover:<size>	这个命令用于向设备传送一个recovery镜像。 其中<size>是此镜像文件的大小。它将在设备中做如下操作： - 创建一个/tmp/update文件 - 读取文件大小，然后读取文件内容写入上面创建的新文件中 - 当上面工作完成后，将创建一个文件，名为：/tmp/update.start。 注意：此命令只有在设备处于recovery模式下才会生效；否则/tmp这个目录是

		不存在的，连接将会被马上终止
	jdwp:<pid>	连接运行于<pid>进程中的JDWP线程
	track-jdwp	这个命令用于周期性地发送JDWP Pid列表到ADB Client。 每次返回的数据格式如下： <hex4>：数据的大小，还是以4字节、十六进制表示。 <content>：pid列表描述。每个pid以下面的格式表示： <pid>“\n”
	sync:	这个命令用于启动文件同步服务。它是“adb push”和“adb pull”的实现前提

2．ADB Server<- ->ADB Daemon

ADB Server和ADB Daemon间的交互，官方文档中称之为一个“transport”。目前系统支持两种形式的transport。如下所示：

- usb transport

顾名思义，这说明ADB Server和Daemon是通过USB线进行连接的。通常对于真实的Android设备，都采用这种形式。

- local transport

对于运行于研发主机之上的模拟器，ADB Server将通过TCP端口直接与其连接。

当然，local transport的连接方式并不局限于模拟器。换句话说，ADB Server与真机设备同样也可以进行TCP连接与通信。另外，locoal transport也并不仅仅适用于ADB Server与Daemon运行于同一主机的情况——理论上它们可以分布在世界各地的任何角落，只不过到目前为止ADB还没有实现这一功能。

25.4 SDK Layoutlib

Layoutlib是SDK系统工具集中的一个重要组成部分，它是Android IDE（如Eclipse、Android Studio等）实现UI界面预览的关键。

Layoutlib在Android源码工程中的路径是：/frameworks/base/tools/layoutlib，主要组成元素如下所示。

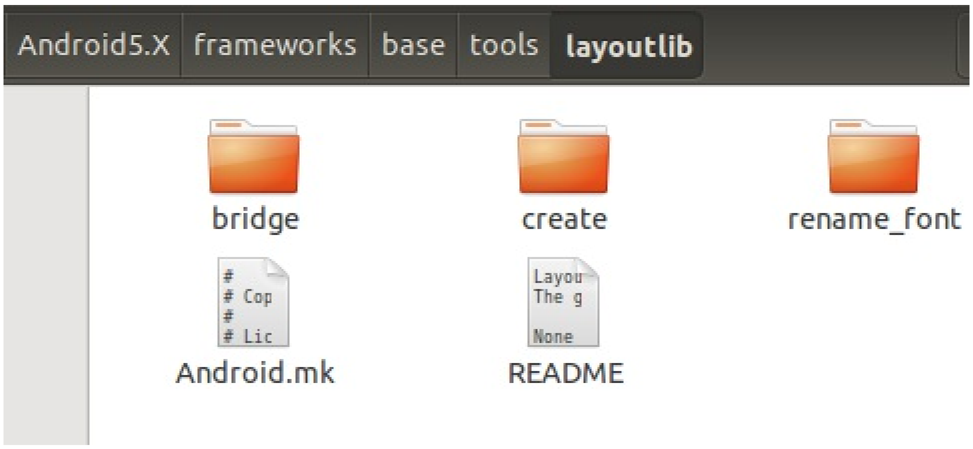

我们先来看下README文件对它的描述：

```
/*README*/
Layoutlib is a custom version of the android View framework desig
The goal of the library is to provide layout rendering in Eclipse

None of the com.android.* or android.* classes in layoutlib run o
```

大家注意看一下上述描述中的两个重点：

- Custom version of the android View framework

这句话说明它是基于Android View框架的一个定制版本。或者用更直白的话来讲，就是它根据自己的需求对View框架进行了改写。那么目的是什么呢？

- Provide Layout rendering in Eclipse

可能有的读者已经猜到了，其目的就是为了给Eclipse（IntelliJ

IDEA和Android Studio的情况也是类似的）等IDE提供程序的UI界面渲染功能。

大家参考图25-10所示的截图应该就很清楚了。

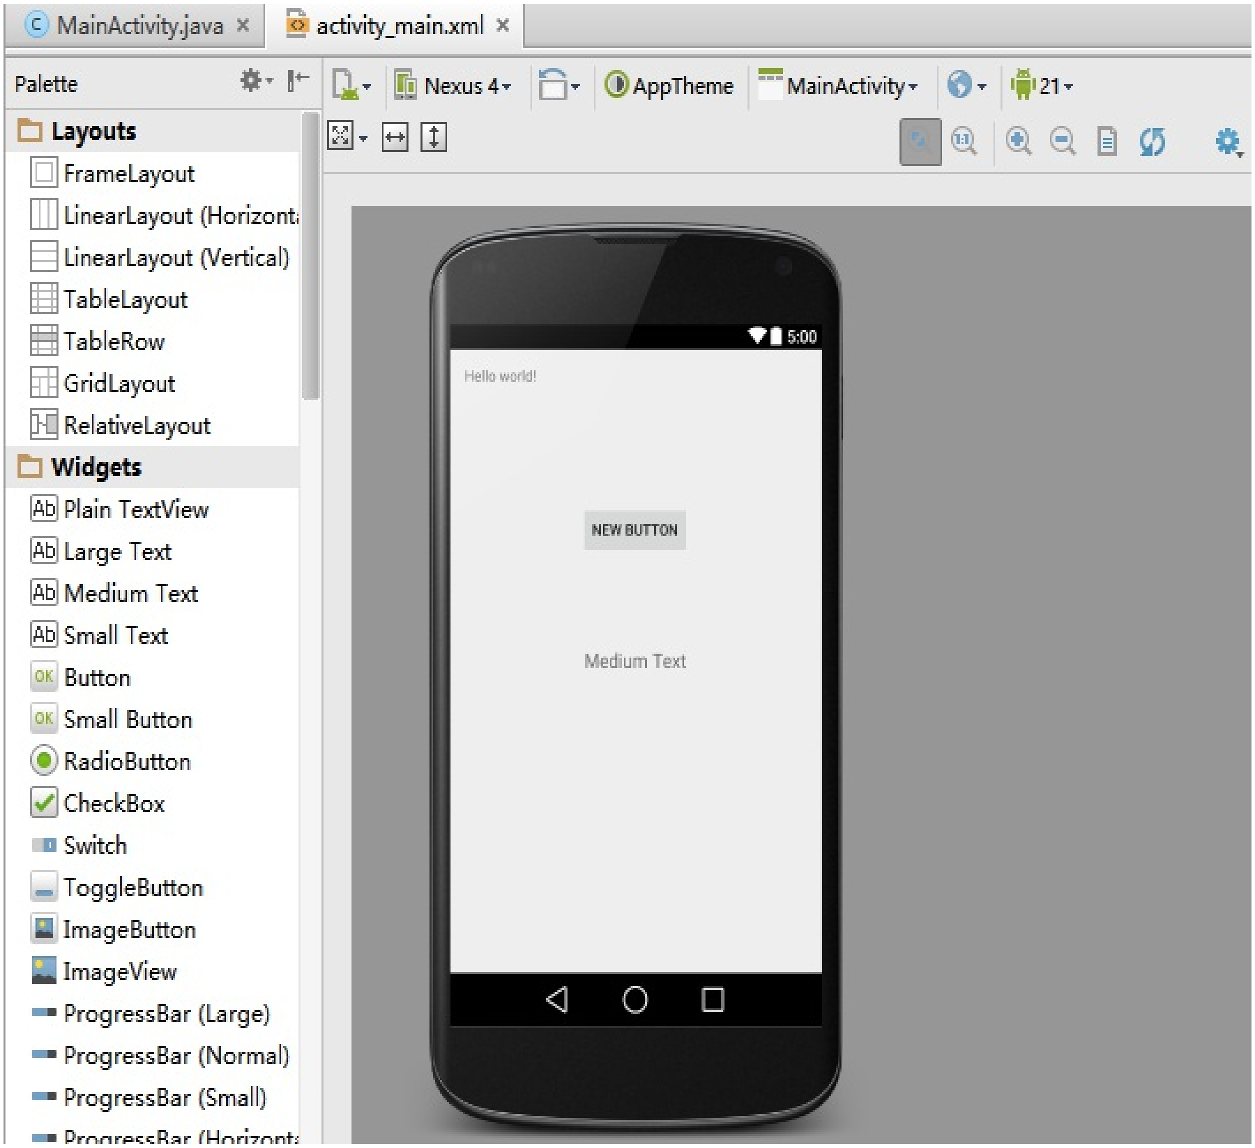

▲图25-10　Layoutlib负责IDE中的UI界面渲染

图25-10中activity_main.xml这个layout的界面效果可在右侧的手机框中实时显示出来，借助的就是Layoutlib这个工具。它的作用有点类似于Android模拟器，但是在原理上却有极大差异——Emulator是处于“运行时状态”的，它需要借助于系统Image来呈现界面效果；而Layoutlib产生界面的过程则是“静态”完成的。

但是在处理这个“静态”界面的过程中，Layoutlib和Emulator一样会用到系统Image提供的元素，比如View Framework。只不过这些系统元素需要做一些必要的改造，才能为Layoutlib所用。不难推断，实现渲染UI界面这样一个功能，实际上是要做大量工作的。

读者可能会有疑问，既然Layoutlib承担的任务并不简单，那为什么/frameworks/base/tools/ layoutlib中的源码并不多呢？这是因为上述的文件夹目录只包含了Layoutlib的部分实现，真正的“大头”还在于Android View Framework，以及如何改造view framework。大家如果有兴趣的话可以分析一下Layoutlib的Android.mk和源码实现，从中就可以梳理清楚它与View Framework之间“千丝万缕的关系”了。

25.5 TraceView和Dmtracedump

我们知道，Android开发者可以在代码中添加Debug类提供的各种调试函数，然后通过SDK中的TraceView工具来做有针对性地分析。接下来我们通过一个简单的范例来实际演示下TraceView的用法。

Step1. 新建Android工程。

创建一个简单的Android应用程序工程，你可以通过各种IDE来快速完成这一步

Step2. 在需要被追踪的起点和终点分别加上Debug提供的各类配套函数。譬如在Activity的onCreate和onStop中添加起止函数：

```
@Override
public void onCreate(Bundle savedInstanceState) {
    Debug.startMethodTracing("TraceTest");
    super.onCreate(savedInstanceState);
    setContentView(R.layout.main);
}

@Override
protected void onStop() {
    super.onStop();
    Debug.stopMethodTracing();
}
```

“TraceTest”是trace文件的名称，默认值是dmtrace.trace;如果没有特别指定的话，这个文件的最大值是8MB。程序从startMethodTracing开始记录数据到缓存中，并在stopMethodTracing时将这些数据写入文件——如果在此之前文件大小达到上限，则系统将提前结束录制，并有相应提示。

因为trace文件会被保存到外部设备（如SD卡）中，所以程序必须要申请WRITE_EXTERNAL_STORAGE 权限，否则运行时会报错。

Step3. 运行应用程序，LogCat中会有trace文件创建成功与否的提示，如下所示：

```
15:09:48.262  13472-13472/com.example.TraceTest I/dalvikvm:  TRACE STARTED: '/storage/emulated/legacy/TraceTest.trace' 8192KB
15:14:21.277  13472-13472/com.example.TraceTest I/dalvikvm:  TRACE STOPPED: writing 278282 records
```

Step4. 我们可以用ADB工具将上述的trace文件拉取到本地进行分析

```
adb pull /storage/emulated/legacy/TraceTest.trace D:\
```

Step5. trace文件虽然是文本格式，但直接查看并不方便，因而我们需要借助TraceView工具来加快分析。截图如图25-11所示。

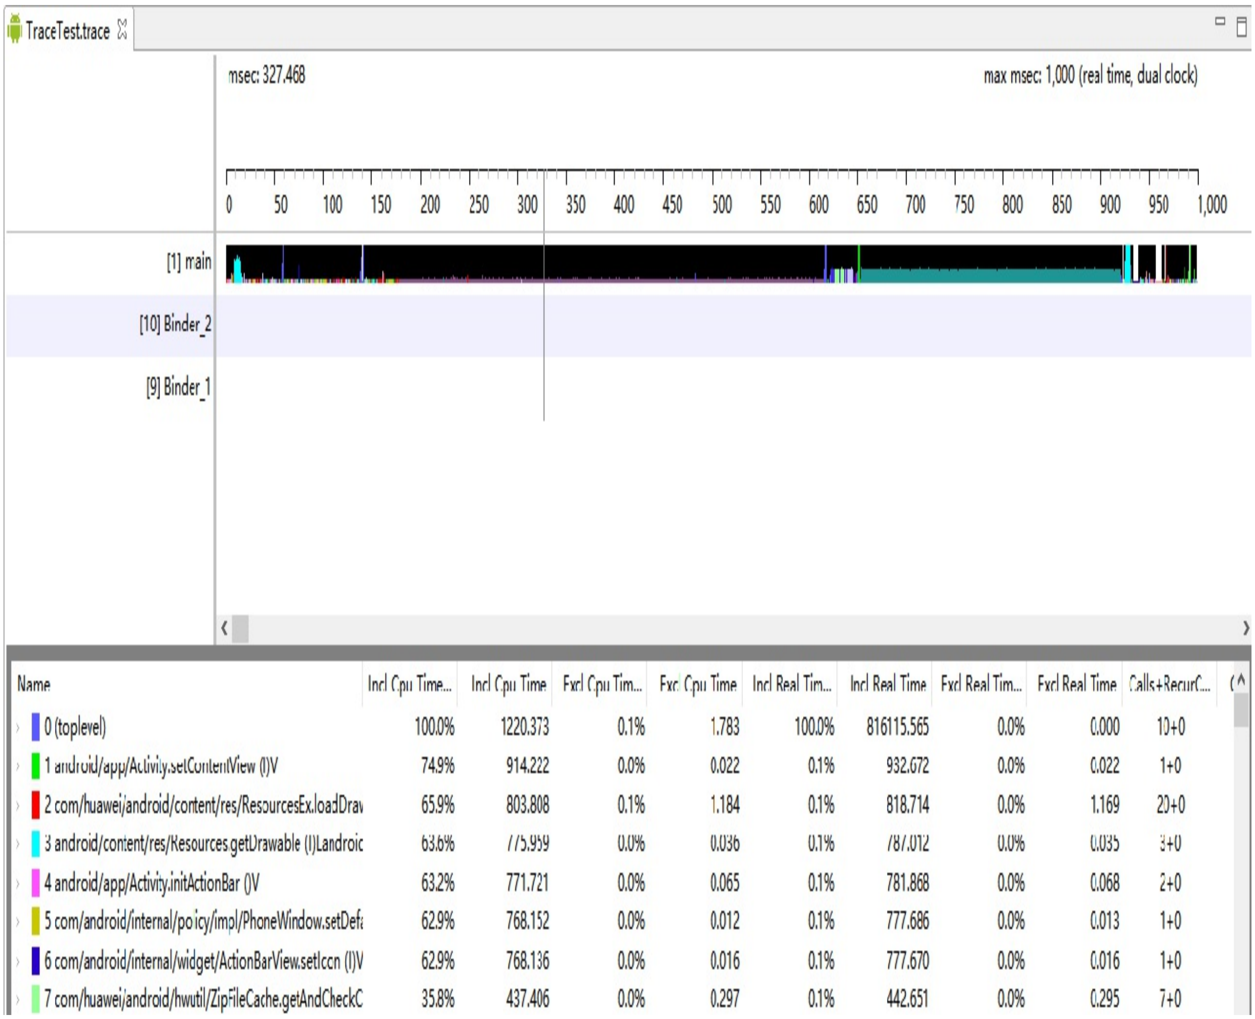

▲图25-11　界面图

TraceView分为两个部分：

- Timeline Panel

上半部分是一个时间轴，逐行展示各个线程的执行情况。向右为时间递增方向，并以不同颜色区分各被调用的函数。

- Profile Panel

下半部分提供了每个函数所花费时间的统计信息。根据官方文档的说明，目前有两种类型的时间统计：Inclusive和Exclusive times。后者是指本函数运行所花费的时间，而inclusive则是本函数及它所调用的函数的时间总和。调用和被调函数分别被称为“parents”和“children”，并分别以紫色和黄色显示。

因为trace中保存了各个函数间的调用关系，我们自然而然地想到是否可以由此生成函数间的“调用树”呢？答案是肯定的，而且Android也提供了现成的工具来达到这一目标，即Dmtracedump。不过这个工具生成调用树的速度比较慢，感兴趣的同学可以自行尝试。

值得一提的是，上述内容中只讲述了trace机制的其中一种关键用法。事实上它是Android虚拟机内部的重要组成部分，并支持多种工作方式，总结如下：

- 通过系统属性来控制trace

当AndroidRuntime启动一个虚拟机时（可以参见本书Android虚拟机章节的分析），它会通过解析各种系统参数来对后者进行配置，其中与trace相关的处理如下所示：

```
/*
* Tracing options.
*/
property_get("dalvik.vm.method-trace", propBuf, "false");
if (strcmp(propBuf, "true") == 0) {
    addOption("-Xmethod-trace");
    parseRuntimeOption("dalvik.vm.method-trace-file",
                       methodTraceFileBuf,
                       "-Xmethod-trace-file:");
    parseRuntimeOption("dalvik.vm.method-trace-file-siz",
                       methodTraceFileSizeBuf,
                       "-Xmethod-trace-file-size:");
    property_get("dalvik.vm.method-trace-stream", propBuf, "false");
    if (strcmp(propBuf, "true") == 0) {
        addOption("-Xmethod-trace-stream");
    }
}
```

一旦虚拟机参数中带有使能Trace的控制选项后，Runtime::start()内部就会主动调用Trace::Start()来完成对trace的启动，最终效果和前述添加Debug.startMethodTracing的方法是一样的。

- 利用/system/bin/am来控制trace

保存在bin路径下的am是一个shell脚本，它提供了Activity相关的很多操作，包括本小节所讲解的trace机制。具体实现上，am将运行am.java文件，后者则进一步利用ActivityManager Service所提供的服务来开启/关闭trace。因为AMS和各个应用程序进程间保持着通信关联，所以可以很容易地把trace控制消息推送给它们。各应用程序会在主线程中处理这些消息，而且它们同样也是借助于Debug.startMethodTracing/Debug.stopMethodTracing来开关trace的。有兴趣的读者可以阅读ActivityThread中的startProfiling和stopProfiling了解详情。

- 利用Debug.startMethodTracing/Debug.stopMethodTracing来控制trace

这也是本小节前面部分所讲解的方式。这种手法需要源代码的配合，因而操作上有一定局限性；优点就是可以精确地将trace范围控制在特定的代码行处。

由此可见trace支持的控制方式也是挺多的，开发人员可以根据实际情况选择适合自己的具体手段。

25.6 Systrace

Android的SDK中还提供了一个分析应用程序UI运行性能的工具，名为Systrace（对应的文件夹是SDK/platform-tools/systrace）。Systrace是由Python书写完成的，因而用户在使用前需要安装Python的运行环境。

经验表明应用程序需要保证60帧/秒的UI绘制速率才能让用户感觉到交互过程是“流畅”的，所以我们在开发程序时需要有工具来帮助衡量应用程序是否达到了这一要求——Systrace就可以做到这点。另外，它还额外提供了针对系统和应用程序在内的很多其他有效的分析方式，通常情况下我们可以结合起来分析。

Systrace的启动方法比较多，既可以在IDE中通过单击按键的方式来调用，也可以利用Android Device Monitor中的 来启动，还能直接通过命令行的方式来运行，格式如下：

```
python systrace.py [options] [category1] [category2] ... [categor
```

其中Options各项内容及释义如表25-24所示：

表25-24　Systrace支持的各类选项及释义（针对Android 4.3及以上版本）

Options	Description
-h, --help	显示帮助信息
-o <FILE>	指定HTML报告的文件名称
-t N, --time=N	指定需要跟踪的时间长度，默认值是5秒
-b N, --buf-size=N	指定最大的buffer size，以KB为单位

-k <*KFUNCS*> --ktrace= <*KFUNCS*>	指定需要跟踪的内核功能，是一个以逗号分隔的列表
-l, --list-categories	指定需要被跟踪的类别标签。可选的包括： gfx --- Graphics input --- Input view --- View wm --- Window Manager ……
-a <*APP_NAME*> --app= <*APP_NAME*>	需要被跟踪的应用程序的包名列表，以逗号分隔。要特别注意的是，开发者需要在代码中添加trace类提供的各种接口才能生效
--from-file= <*FROM_FILE*>	从文件中生成一份Systrace报告
-e <*DEVICE_SERIAL*> --serial= <*DEVICE_SERIAL*>	从连接的设备中选择需要被跟踪的设备

Android Device Manager把这些选项进行了图形化，如图25-12所示。

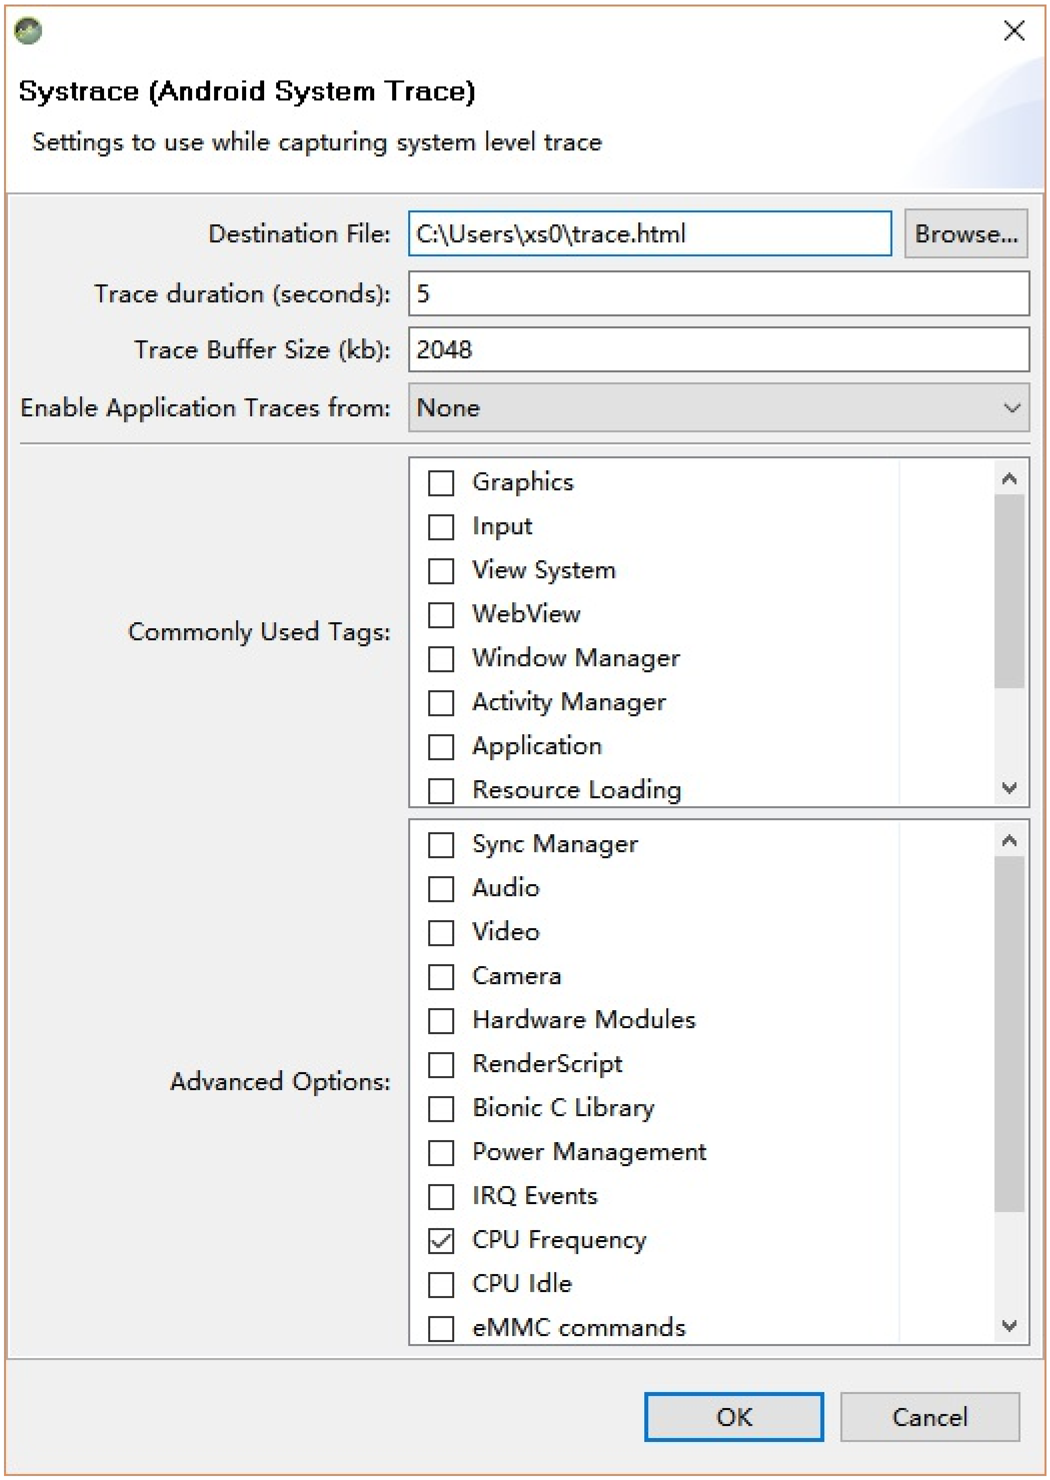

▲图25-12　Systrace的图形化界面

图25-13所示是捕获“sched gfx view wm”所生成的一个报告范例。

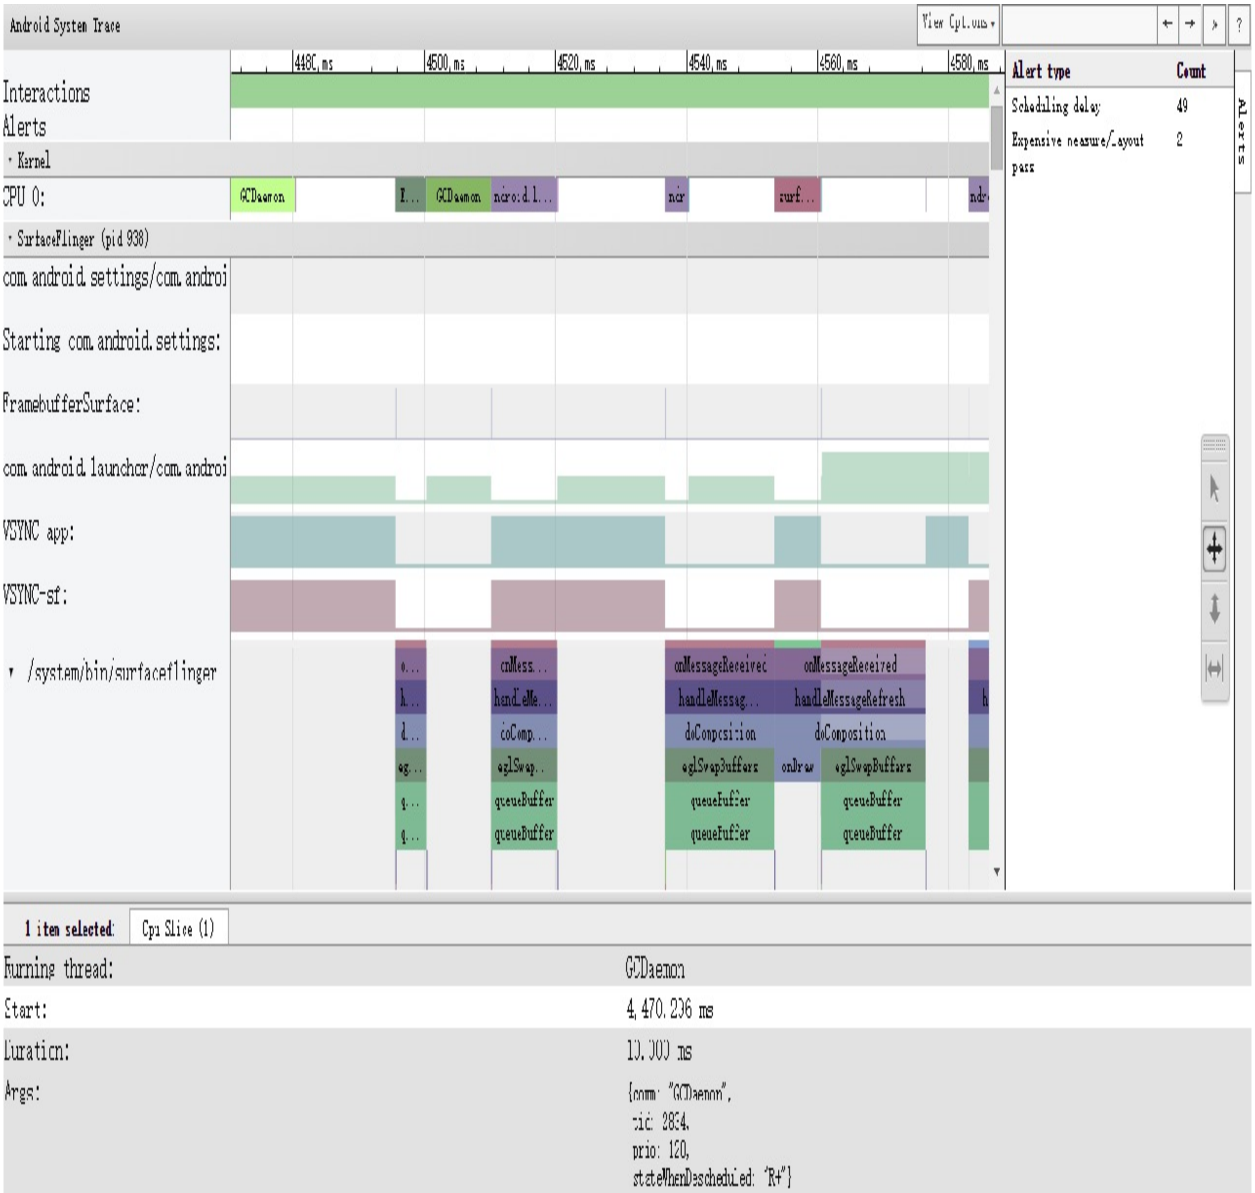

▲图25-13　报告范例

在分析的过程中，我们要特别注意那些绘制时间超过16ms的操作，因为这些很可能是导致掉帧，进而引发界面“不流畅”的罪魁祸首。同时Systrace也提供了引导信息来帮助开发者改善这些问题，譬如右上角的Alert就是对于程序中当前存在问题的警示;而对于消耗时间过长的操作，则会有特别标注，如图25-14所示。

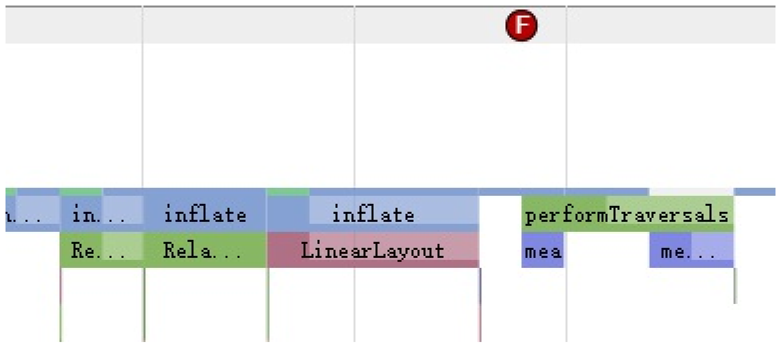

▲图25-14　界面图

红色的图标F（运行图可看到颜色）表示当前的操作远超过常规时间，因而需要用户特别注意。

关于Systrace的更多用法与信息，希望读者可以结合实际的性能优化范例来学习体会，相信会有不小的收获。

当然，这些分析工具并不是Android操作系统专有的。事实上我们要看到Android在Instruments/Profiler工具上与Apple xCode、Visual Studio和Tizen等操作系统还有一定的差异。其中Apple xCode以完备的Instruments而备受开发人员喜爱，如图25-15所示。

Apple xCode提供了各种类型的监测工具，包括Memory Leak、CPU、GPU等。开发者可以在如上所示的统一界面中添加所要监控的对象，以直观的方式查看profile结果。

而Tizen系统则明显吸收了xCode的这些“优势”，所以在功能上它们是比较相似的——只不过前者暂时还没有xCode做得那么完善。功能截选如图25-16所示。

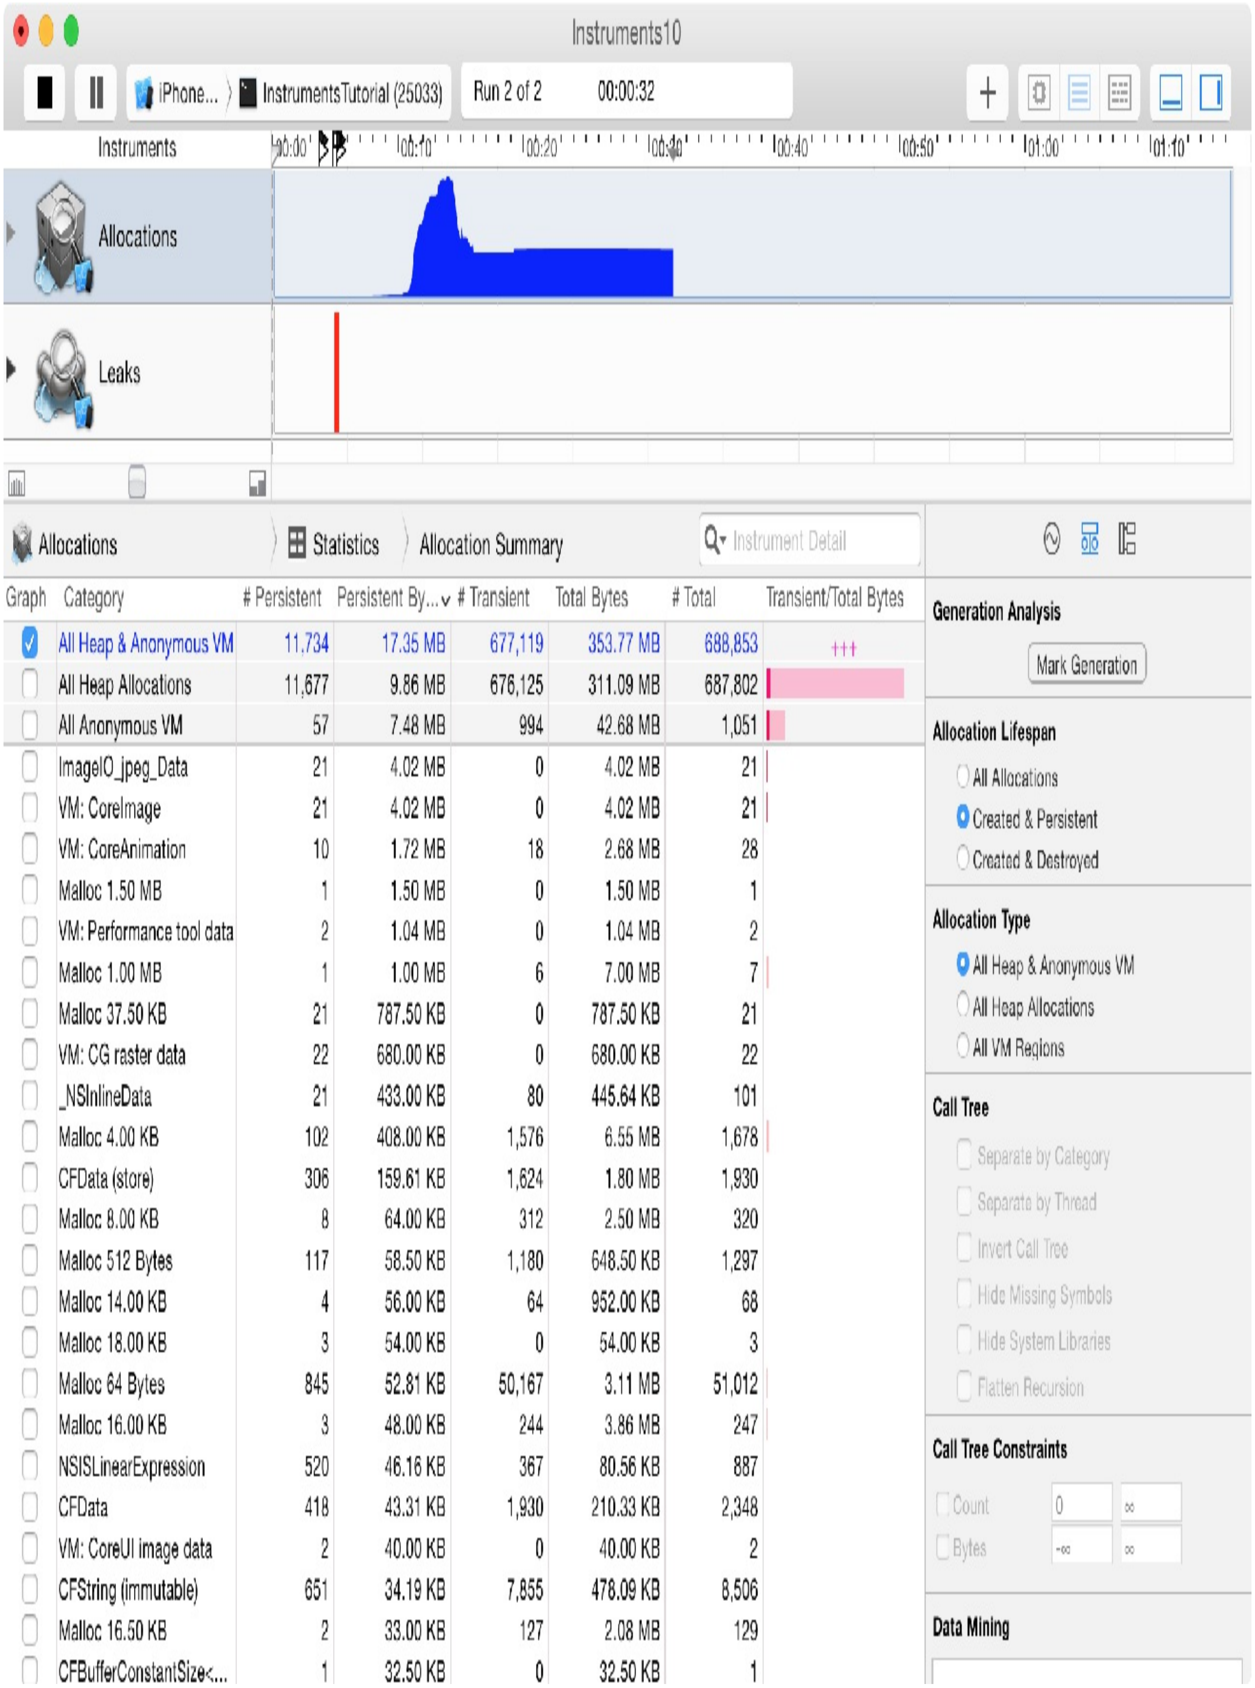
Instruments10
iPhone...
InstrumentsTutorial (25033)
Run 2 of 2
00:00:32
Instruments
Allocations
Leaks
Allocations
Statistics
Allocation Summary
Instrument Detail
Graph Category # Persistent Persistent By... # Transient Total Bytes # Total Transient/Total Bytes
All Heap & Anonymous VM 11,734 17.35 MB 677,119 353.77 MB 688,853
All Heap Allocations 11,677 9.86 MB 676,125 311.09 MB 687,802
All Anonymous VM 57 7.48 MB 994 42.68 MB 1,051
ImageIO_jpeg_Data 21 4.02 MB 0 4.02 MB 21
VM: CoreImage 21 4.02 MB 0 4.02 MB 21
VM: CoreAnimation 10 1.72 MB 18 2.68 MB 28
Malloc 1.50 MB 1 1.50 MB 0 1.50 MB 1
VM: Performance tool data 2 1.04 MB 0 1.04 MB 2
Malloc 1.00 MB 1 1.00 MB 6 7.00 MB 7
Malloc 37.50 KB 21 787.50 KB 0 787.50 KB 21
VM: CG raster data 22 680.00 KB 0 680.00 KB 22
_NSInlineData 21 433.00 KB 80 445.64 KB 101
Malloc 4.00 KB 102 408.00 KB 1,576 6.55 MB 1,678
CFData (store) 306 159.61 KB 1,624 1.80 MB 1,930
Malloc 8.00 KB 8 64.00 KB 312 2.50 MB 320
Malloc 512 Bytes 117 58.50 KB 1,180 648.50 KB 1,297
Malloc 14.00 KB 4 56.00 KB 64 952.00 KB 68
Malloc 18.00 KB 3 54.00 KB 0 54.00 KB 3
Malloc 64 Bytes 845 52.81 KB 50,167 3.11 MB 51,012
Malloc 16.00 KB 3 48.00 KB 244 3.86 MB 247
NSISLinearExpression 520 46.16 KB 367 80.56 KB 887
CFData 418 43.31 KB 1,930 210.33 KB 2,348
VM: CoreUI image data 2 40.00 KB 0 40.00 KB 2
CFString (immutable) 651 34.19 KB 7,855 478.09 KB 8,506
Malloc 16.50 KB 2 33.00 KB 127 2.08 MB 129
CFBufferConstantSize<... 1 32.50 KB 0 32.50 KB 1
Generation Analysis
Mark Generation
Allocation Lifespan
All Allocations
Created & Persistent
Created & Destroyed
Allocation Type
All Heap & Anonymous VM
All Heap Allocations
All VM Regions
Call Tree
Separate by Category
Separate by Thread
Invert Call Tree
Hide Missing Symbols
Hide System Libraries
Flatten Recursion
Call Tree Constraints
Count
Bytes
Data Mining

▲图25-15　Apple xCode提供的Instruments工具（其是开发人员分析问题的利器）

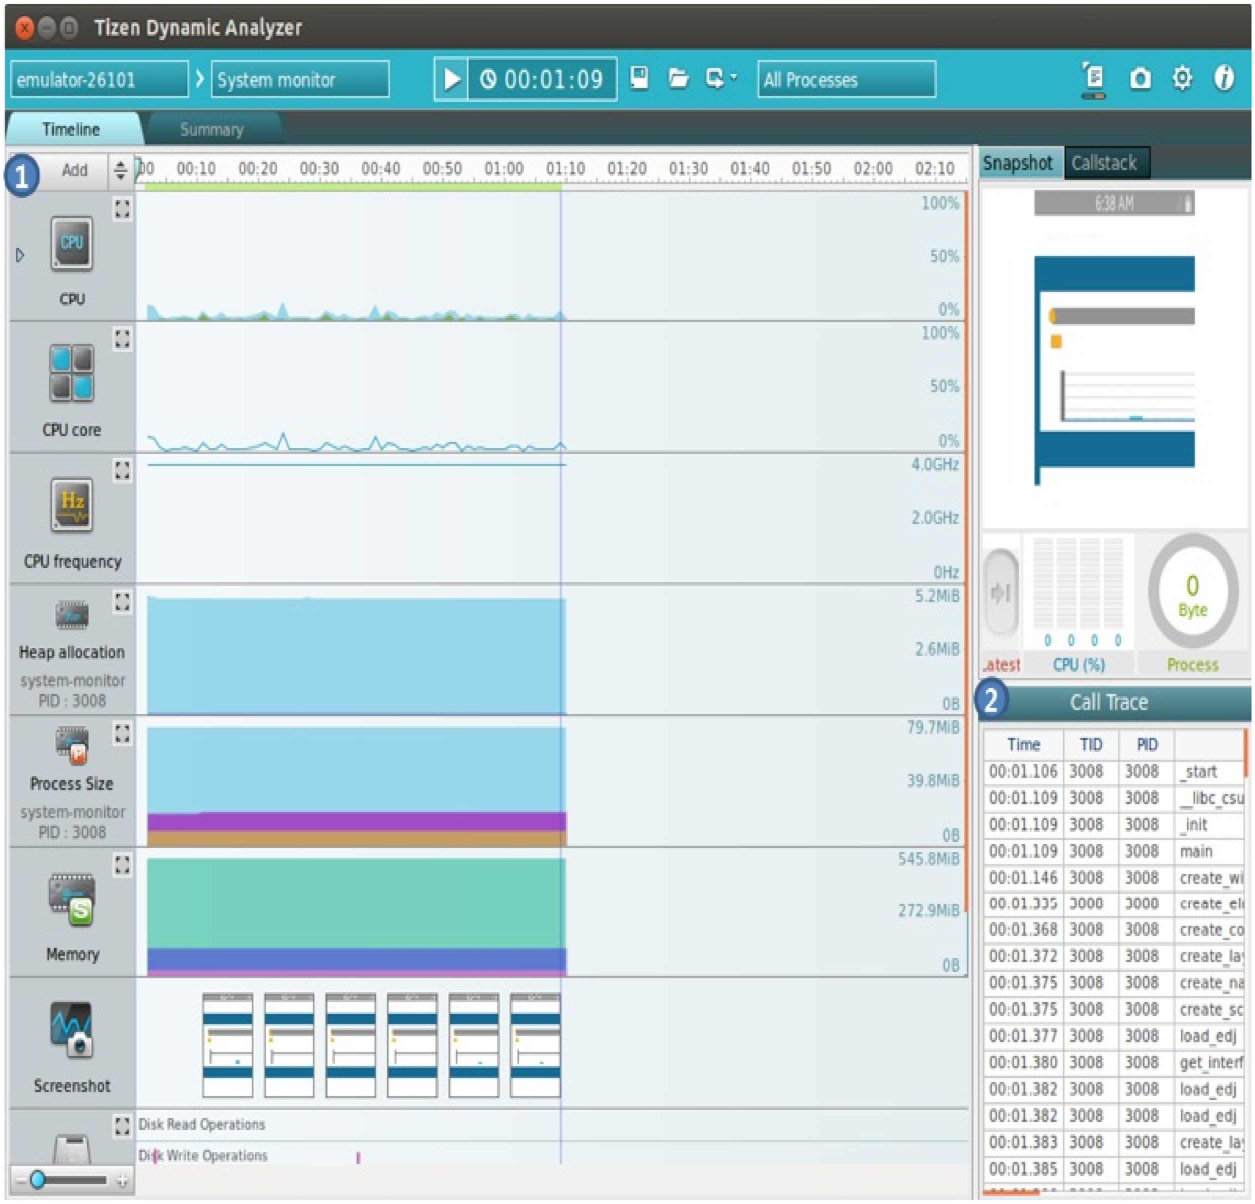

▲图25-16　Tizen Dynamic Analyzer

不同操作系统中的监控机制存在不小的差异，因而体现在具体的实现上就难免有些不同。合理利用系统提供的性能监测和问题定位工具有利于我们尽早发现隐藏在程序中的潜在问题，从而有效提高代码的可靠性和程序的稳定性。

最后我们对Android中的常用Profile工具做了一个小结，供大家参考借鉴。如表25-25所示。

表25-25　Android常用工具一览表

Tool	Description
Traceview	提供了程序中各个线程和函数的执行起始时间，以及单个函数内部具体的时间消耗
Dmtracedump	从trace log中生成图形化的函数调用关系图
Memory Monitor	以时间顺序展示程序对Heap内存空间的占用情况
Heap Viewer	占用内存空间的各个对象的详细信息，包括对象所属Class，所属线程、分配内存的代码位置等
Allocation Tracker	这一项和前述两项是Android系统中分析应用程序内存问题的“最佳搭档”。一个典型的使用流程是：我们首先使用Memory Monitor来观察程序是否经常性发生GC事件（问题是否存在）——答案如果是肯定的，开发者再进一步利用Heap Viewer来甄别出候选的可疑对象类型（导致问题的可疑对象是什么），并借助于Allocation Tracker来确定发生问题的代码在哪个位置（问题是如何产生的）。大家可以参阅本书第5章节中对内存管理优化的分析
Memory Analyzer Tool	MAT并非由Android系统提供，而是Eclipse基金会开发的一款通用型的JVM内存问题诊断分析器。如果开发人员在使用上述几个内存工具后仍无法解决问题，可以尝试通过MAT来做进一步分析。MAT的官方网址是：https://eclipse.org/mat

Hierarchy Viewer	分析应用程序的UI界面框架，从而找出是否有影响性能的冗余实现
Systrace	可以让开发者对整个Android设备中的进程和线程执行情况进行分析。这个工具的独特优势是可以针对UI界面的各个绘制帧进行跟踪，并从中得出是否存在掉帧的情况，同时还有相应的解决方法推荐
Tracer for OpenGL ES	用于辅助开发人员分析OpenGL ES程序中的代码问题。如捕获OpenGL ES的命令以及各帧的信息
Development Tools（安装于Android设备上）	各个ROM厂商通常会定制自己的开发调试设置，如图25-17所示的范例截图

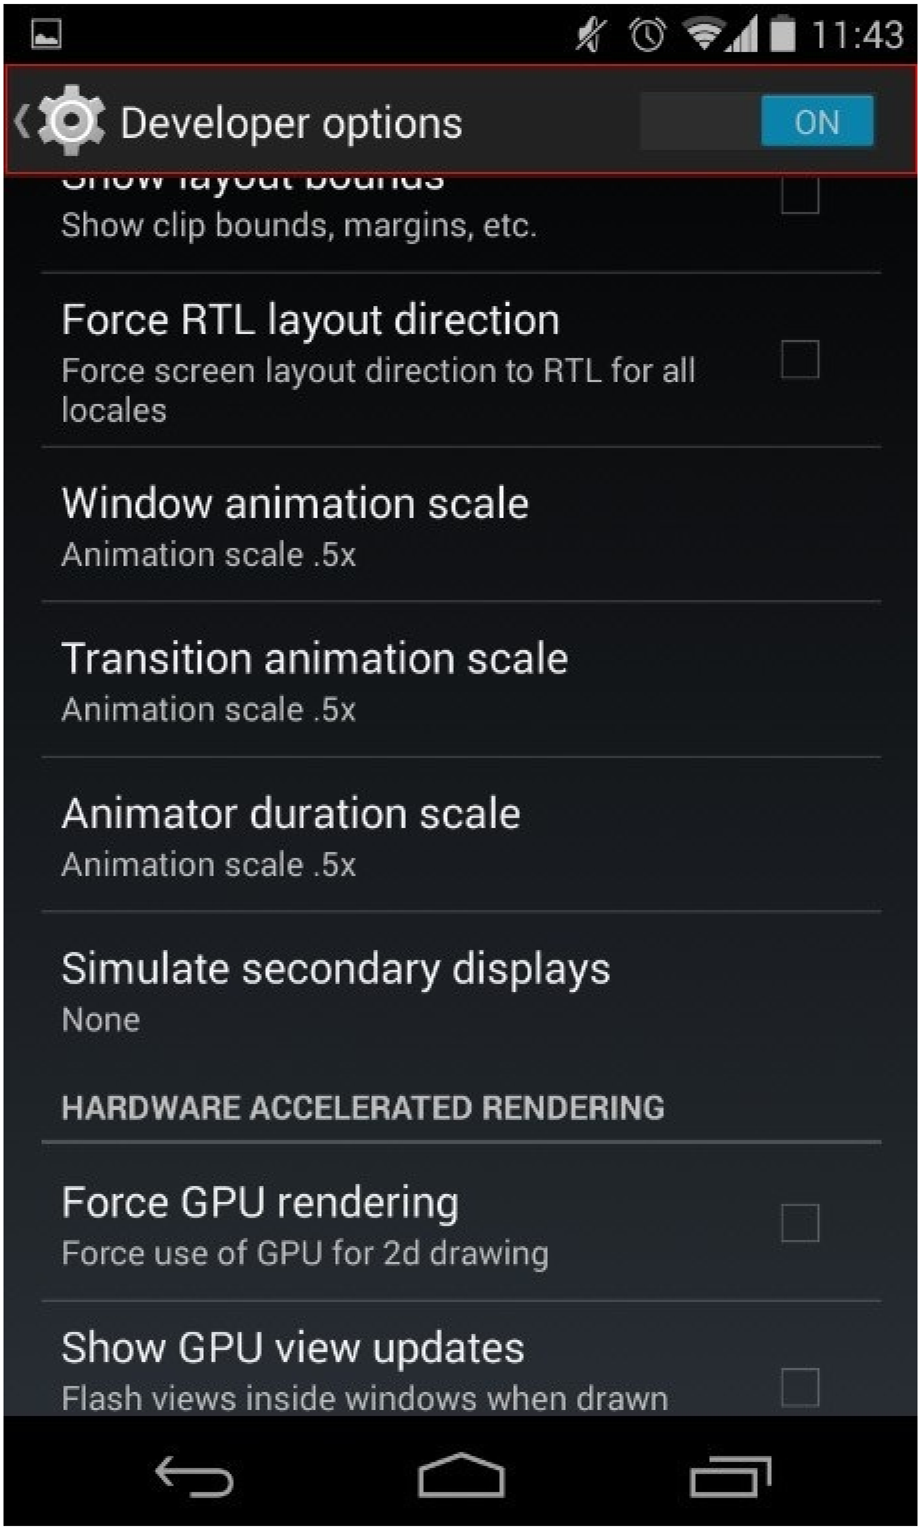

▲图25-17　Developer Options范例图

25.7　代码覆盖率统计

代码覆盖率是用于衡量测试用例完整性的重要手段之一，可以说绝大多数对质量要求严苛的公司都会对此有量化要求。例如笔者曾和Google内部人员做过交流，他们通常都会要求项目的代码覆盖率达到85%以上。

从技术角度来看，实现代码覆盖率的方法很多，它们大致可以被归为图25-18所示的几个分类。

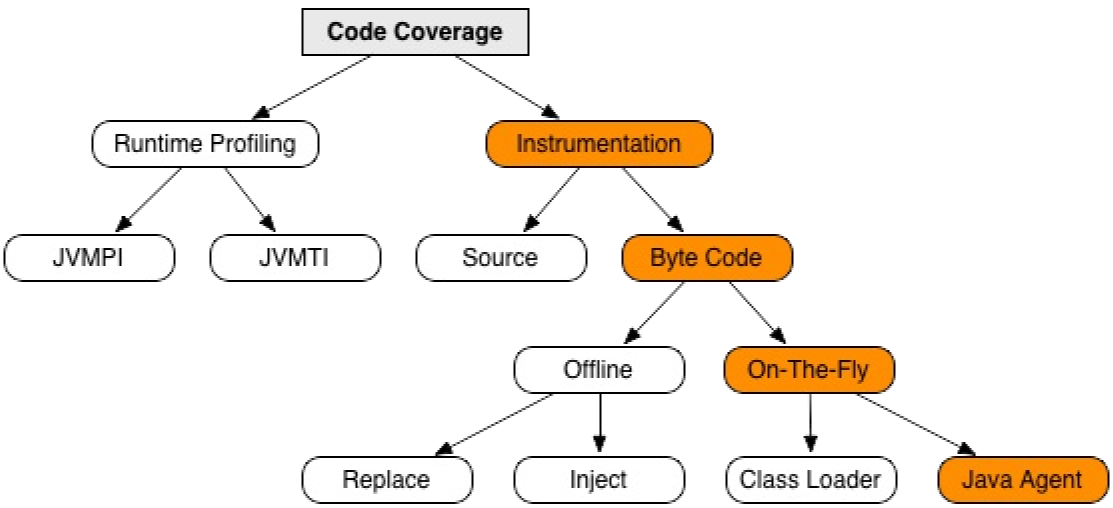

▲图25-18　代码覆盖率的实现方法
（引用自Jacoco官方文档）

目前主流的代码覆盖率工具有Emma、Jacoco、Clover等。Jacoco因为其功能全面，开源社区活跃等诸多优点，可以说是当前Java界最流行的代码覆盖率工具之一。

其中Eclemma是一个Eclipse插件，其开始的版本中使用的是Emma，后来则改用Jacoco作为它的核心基础库。

总的来说，代码覆盖率框架支持两种工作模式，即On-the-fly instrumentation和Offline instrumentation。

On-the-fly简单而言就是利用代码覆盖率工具自己的Class Loader来代替程序原先的加载器，并在动态运行时加入代码覆盖率统计信息。

这种方式有一定的局限性，例如无法适用于如下的场景：

- 不支持Java Agents的运行时环境；
- 在部署时无法配置JVM参数的情况；
- 需要将字节码转化为其他虚拟机码的情况，如Android Dalvik VM；
- 与其他agents会产生运行时冲突的情况；
- 需要被Boot Class Loader加载的类。

由于上述这些原因，Android系统选择的是代码覆盖率工具（以前是Emma，目前是Jacoco）的另一种工作模式，即Offline instrumentation。典型的命令如下所示：

```
java -cp emma.jar emma instr -m overwrite -cp to_be_instrumented.
```

其中to_be_instrumented.jar是需要被统计的对象，会被事先做插桩处理。具体到Android的编译环境中，代码覆盖率工具通常需要处理的对象是$(full_classes_jarjar_jar)。为了保证收集的覆盖信息可以与源代码建立起正确的关联，通常要求Java编译的是Debug版本。

Android早期版本中使用的代码覆盖率套件是Emma，后来则逐步切换为Jacoco。另外，随着Android M版本中Jack编译器的出现，情况又发生了一些变化。因为Jack编译器会直接生成dex产物，导致很多依赖于Java中间输出文件的工具无法正常使用，这其中就包括了代码覆盖率工具。按照Google内部的一些资料来看，他们也在尝试解决这个问题——Android N Preview版本中发布的Jacoco子项目或许会是一个比较好的解决方案。

这一点从编译脚本中也可以看出来。如下是Android M版本里的实现：

```
/*build/core/java_library.mk*/
ifeq (true,$(EMMA_INSTRUMENT))
ifeq (true,$(LOCAL_EMMA_INSTRUMENT))
ifeq (true,$(EMMA_INSTRUMENT_STATIC))
LOCAL_STATIC_JAVA_LIBRARIES += emma
endif # LOCAL_EMMA_INSTRUMENT
endif # EMMA_INSTRUMENT_STATIC
else
LOCAL_EMMA_INSTRUMENT := false
endif # EMMA_INSTRUMENT
```

与之对应的Android N版本中的实现：

```
/*build/core/java_library.mk*/
ifeq (true,$(EMMA_INSTRUMENT))
ifeq (true,$(LOCAL_EMMA_INSTRUMENT))
ifeq (true,$(EMMA_INSTRUMENT_STATIC))
# Jack supports coverage with Jacoco
LOCAL_STATIC_JAVA_LIBRARIES += jacocoagent
endif # LOCAL_EMMA_INSTRUMENT
endif # EMMA_INSTRUMENT_STATIC
else
LOCAL_EMMA_INSTRUMENT := false
endif # EMMA_INSTRUMENT
```

由于历史原因，Android编译脚本中与代码覆盖率相关的功能仍然沿用“Emma”这个词，但是内部实现却一直在发生变化，这一点需要大家特别注意。如无特别说明，下面内容中所提到的Emma是指通用的代码覆盖率工具，而不区分具体类型。

上述两个脚本中涉及3个重要的变量，其中EMMA_INSTRUMENT_STATIC会把Emma的核心jar包加入所有开启了Emma功能的模块中（从java_library.mk和package_internal.mk等共用脚本中对EMMA_INSTRUMENT_STATIC的处理过程也可以看出这点）。

和EMMA_INSTRUMENT_STATIC不同的是，EMMA_INSTRUMENT只对libcore起作用。 LOCAL_EMMA_INSTRUMENT则是一个本地变量，是各个模块中使用Emma功能的控制开关。

接下来我们讲解在Android系统中开展代码覆盖率统计（以Framework为例）的典型操作步骤：

（1）Android M版本之前（默认使用的是emma.jar）

Step1. 在/frameworks/base/Android.mk中与Framework.jar相关联的部分添加如下两行语句：

```
LOCAL_MODULE := framework
EMMA_INSTRUMENT := true ##新增语句，打开EMMA开关
LOCAL_EMMA_INSTRUMENT := true ##新增语句，允许Framework这个模块进行代码
```

Step2. 在编译版本之前，先执行如下语句：

```
export EMMA_INSTRUMENT_STATIC=true
```

Step3. 清除之前的编译结果：

```
make clean
```

Step4. 执行编译。

在编译过程中，java.mk会根据上述的配置条件进行Emma相关处理，具体如下：

```
$(full_classes_emma_jar): $(full_classes_jarjar_jar) | $(EMMA_JAR
      $(transform-classes.jar-to-emma)
```

编译系统中的函数统一定义在definitions.mk中，如下所示：

```
/*build/core/definitions.mk*/
define transform-classes.jar-to-emma
$(hide) java -classpath $(EMMA_JAR) emma instr -outmode fullcopy
    $(PRIVATE_EMMA_COVERAGE_FILE) -ip $< -d $(PRIVATE_EMMA_INTERM
    $(addprefix -ix , $(PRIVATE_EMMA_COVERAGE_FILTER))
endef
```

因为Emma的插桩能力体现在一个名为“emma.jar”的Jar包中，所以我们需要调用Java命令来运行它。Emma支持多种参数配置，例如-outfile用于指定em文件（详细记录了Emma对目标所做的插桩内容，以便后面和采集到的运行数据进行合并，最终得到代码覆盖率）的路径，即
$(PRIVATE_EMMA_COVERAGE_FILE)=$(intermediates.COMMON)/coverage.
输入参数$<指的是第一个依赖条件，譬如在这个场景中对应的是
$(full_classes_jarjar_jar)。而“-d”表示输出路径，具体值是
$(PRIVATE_EMMA_INTERMEDIATES_DIR)=$(intermediates.COMMON)/emma_
如果对这些知识点不清楚的话，建议大家可以参考一下本书的编译系统章节。

编译成功后，Framework对应的代码覆盖率中间产物如图25-19所示。

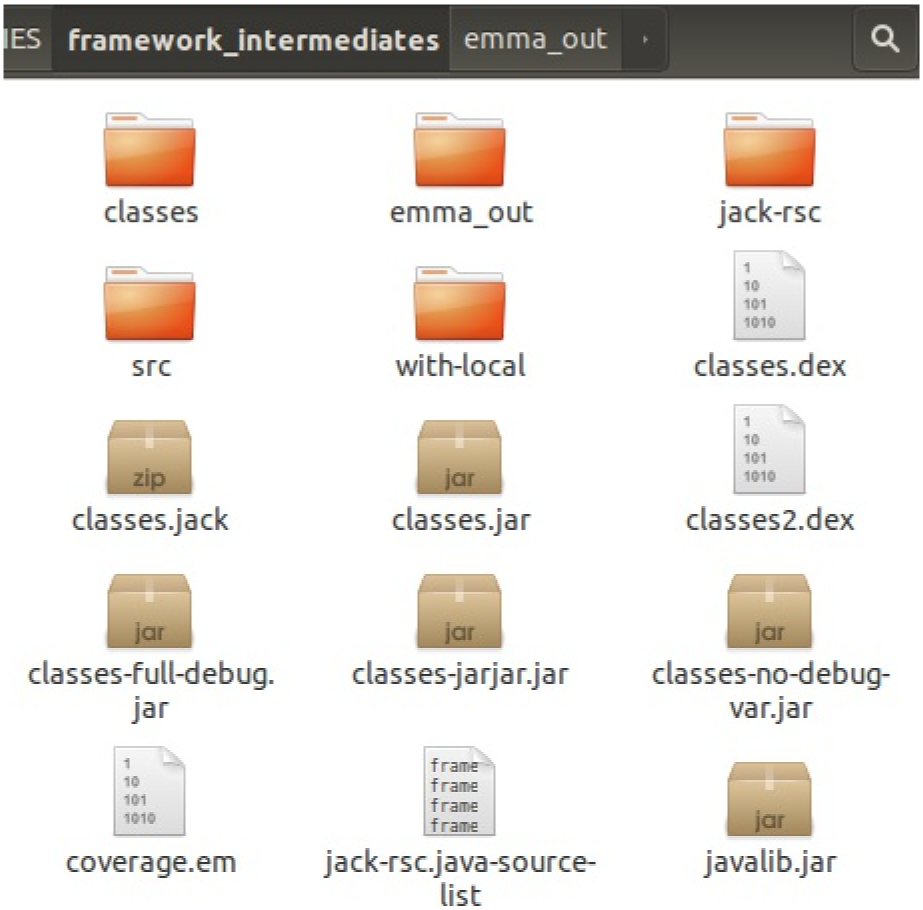

▲图25-19　中间产物

Step5. 将上述步骤中输出的最终软件版本刷写到设备/或模拟器中。

Step6. 执行测试过程，收集代码覆盖率统计文件coverage.ec。

Step7. 利用Emma提供的report功能，结合coverage.ec和coverage.em文件生成最终的报告。典型命令如下：

```
java -cp path/to/emma.jar emma report -r html -in coverage.em -in
```

可见Android系统中自带的Emma工具使用起来还是比较方便的。大家如果在项目开发中有类似需求，建议可以充分利用Android提供的已有工具，达到事半功倍的效果。

（2）Android N版本（默认使用的是jacoco）

由于Jack编译器的工作原理限制，Android系统需要对原先的代码覆盖率统计方式进行调整。例如在java.mk中，full_classes_emma_jar已经不复存在，同时built_dex_intermediate的定义也发生了改变：

```
/*build/core/java.mk*/
ifeq ($(LOCAL_EMMA_INSTRUMENT),true)
$(built_dex_intermediate): PRIVATE_JACK_COVERAGE_OPTIONS := \
    -D jack.coverage="true" \
    -D jack.coverage.metadata.file=$(intermediates.COMMON)/covera
    -D jack.coverage.jacoco.package=$(JACOCO_PACKAGE_NAME)
else
$(built_dex_intermediate): PRIVATE_JACK_COVERAGE_OPTIONS :=
endif
```

中间过程的dex文件会包含插桩后的信息，它的生成过程是：

```
$(built_dex_intermediate): $(jack_all_deps) | setup-jack-server
      @echo Building with Jack: $@
      $(jack-java-to-dex)
```

$(jack-java-to-dex)的定义在Definitions.mk中，它最终会调用jack这个工具链来把Java编译成dex，并且会根据上述的PRIVATE_JACK_COVERAGE_OPTIONS选项同步生成插桩信息。这样一来Android N版本中代码覆盖率统计的成功与否，很大程度上就取决于jack这个编译器的内部实现了。

值得一提的是，AOSP工程的external/jack目录下是空的，jack的真正源码目录是toolchain/jack。参见如下网址：

https://android.googlesource.com/toolchain/jack/

而且我们在git clone jack项目时，还需要加上特定的分支信息（因为其master分支也是空的）。大家可以参考如下的命令行范例：

```
git clone https://android.googlesource.com/toolchain/jack -b ub-j
```

另外，jacoco生成报告的方式和Emma还是有些差异的，大致有如下几种方法。

- jacoco插件

如果你是通过IDE（Eclipse、Android Studio等）创建的工程项目（如Android应用程序工程），那么推荐使用集成的jacoco插件，这样可以省去很多麻烦

- Ant/Maven

假设是非IDE的工程，那么在收集到覆盖率数据后，我们可以利用Ant/Maven来生成最终的报告（到目前为止，jacoco并不支持命令行形式的报告生成方法）。

- 使用jacoco提供的API接口

Jacoco虽然不支持命令行来生成报告，但我们仍然可以利用它提供的API接口来编写自己的报告生成工具。Jacoco官方为此还提供了一个参考范例。

25.8　模拟GPS位置

开发人员在某些情况下需要模拟GPS坐标位置，例如为地图软件构建全球各地的测试场景——此时我们就可以用到Mock GPS Location。

Android系统也考虑到了类似的诉求，并提供了一定的方法来帮助开发者更方便地达成目标。不过随着版本的升级换代，系统提供的具体辅助方式也在不断调整。以真机设备（模拟器上Mock Location的方法有很多，比如利用DDMS提供的专用Panel，用Emulator Console来发送命令等）来说，旧版本的Android系统会在开发者选项中提供一个“允许模拟位置”的开关。在这个选项打开的情况下，我们再借助于某些专用程序便可以实现GPS信息的模拟；而新版本Android系统中的控制粒度更细了，需要用户精确选择可以做Mock Location的程序，对比如图25-20所示。

而且对于那些希望出现在“Select mock loction app”列表中的应用程序，它们还得在Androidmanifest.xml中显式声明下面属性：

```
&lt;uses-permission android:name="android.permission.ACCESS_MOCK_
```

Android 6.0之前，开发者可以利用Settings.Secure.ALLOW_MOCK_LOCATION来判断当前是否开启了位置模拟功能；而Android 6.0之后这个变量就被废弃了，开发者可以尝试使用isFrom MockProvider来做类似的检测。

开发者选项
开启开发者选项
不锁定屏幕
充电时屏幕不会休眠
直接进入系统
开启后不使用系统的锁屏样式，点亮屏幕直接进入系统，需要无屏幕密码
对 SD 卡进行读写保护
应用必须请求读取 SD 卡的权限
打开蓝牙数据包日志
抓取所有蓝牙数据包到一个文件
打开蓝牙调试日志
抓取所有蓝牙调试日志
调试
USB 调试
连接 USB 后启用调试模式
允许模拟位置
允许模拟位置

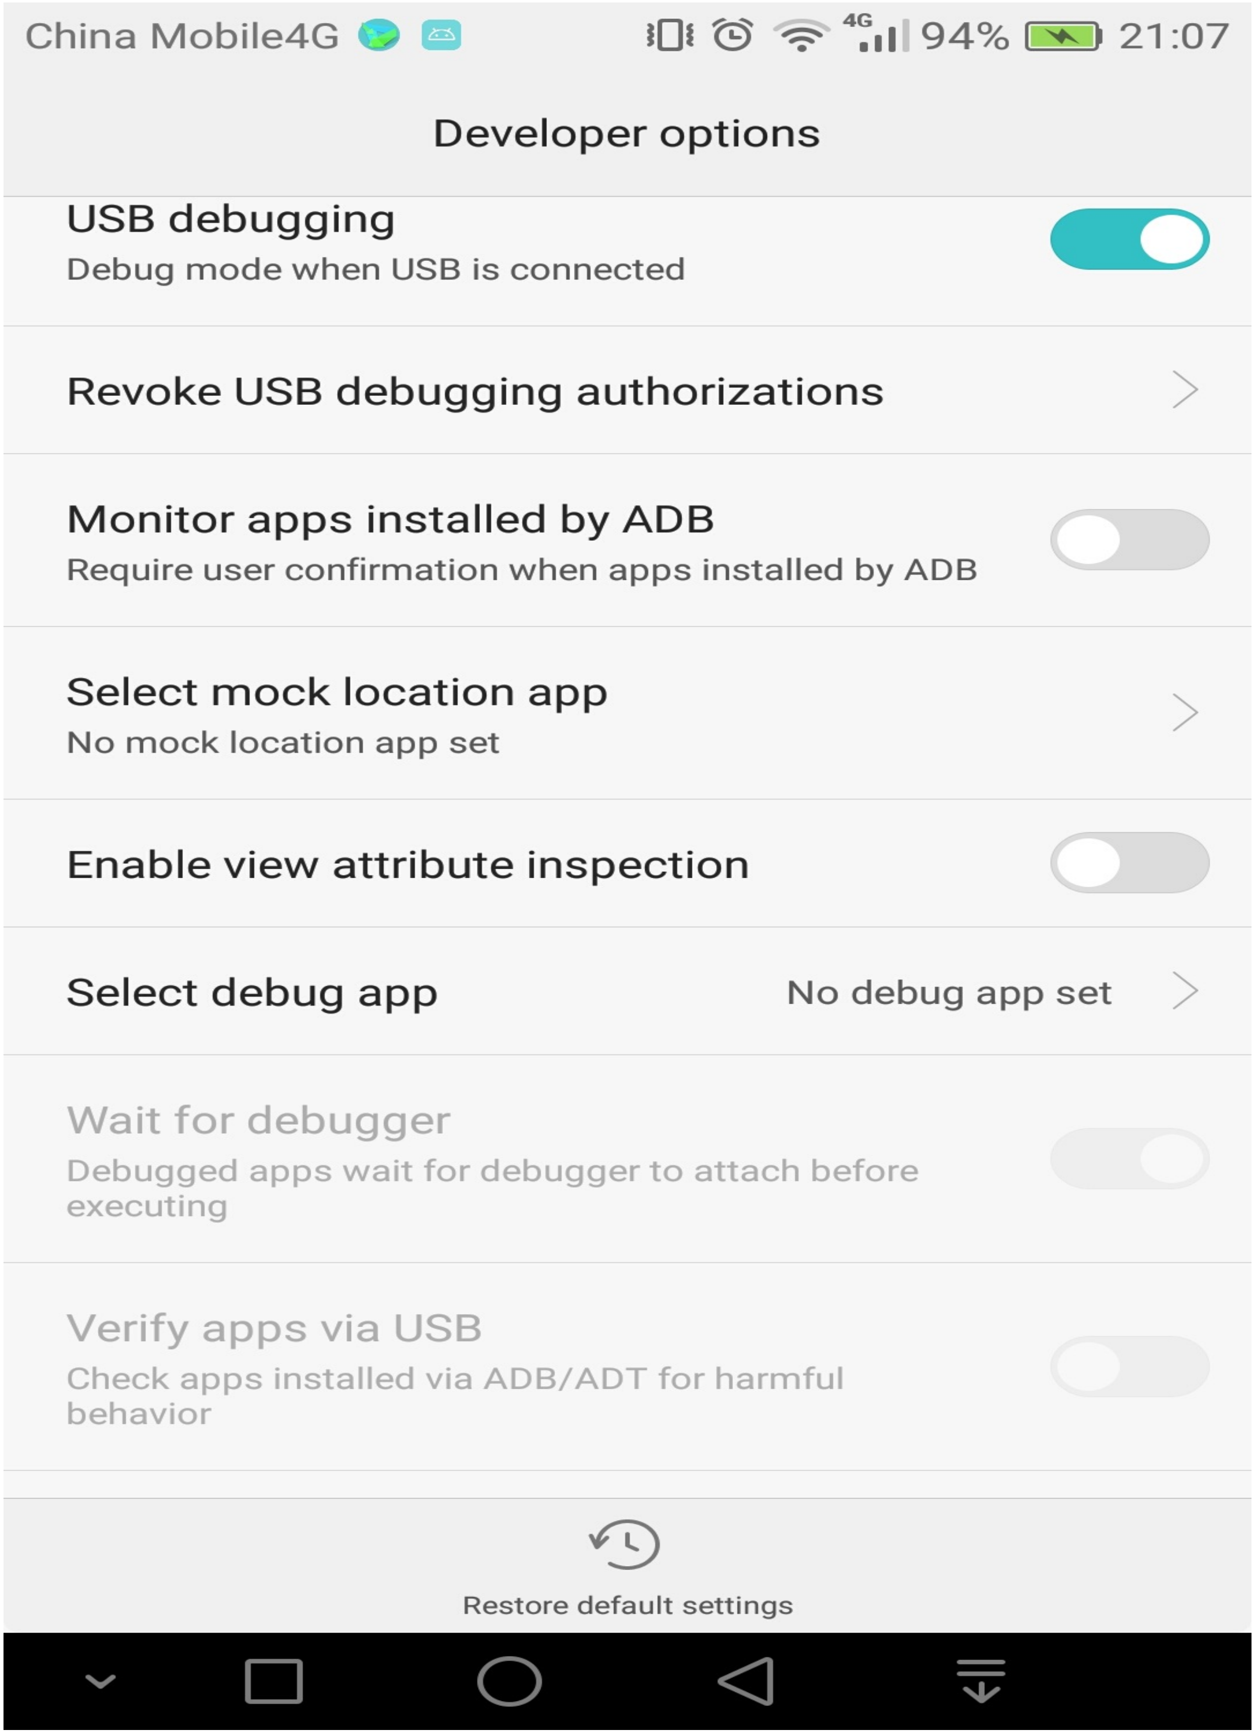
China Mobile4G
94%
21:07
Developer options
USB debugging
Debug mode when USB is connected
Revoke USB debugging authorizations
Monitor apps installed by ADB
Require user confirmation when apps installed by ADB
Select mock location app
No mock location app set
Enable view attribute inspection
Select debug app
No debug app set
Wait for debugger
Debugged apps wait for debugger to attach before executing
Verify apps via USB
Check apps installed via ADB/ADT for harmful behavior
Restore default settings

▲图25-20　Android开发者选项中位置模拟功能的变化
（左：6.0之前　右：6.0之后）

当我们需要将系统的GPS坐标设置成某个指定地点时，可以调用LocationManager中提供的setTestProviderLocation接口，范例如下：

```
String providerString = LocationManager.GPS_PROVIDER;
Location mockLocation = new Location(providerStr);
mockLocation.setLatitude(123);
mockLocation.setLongitude(123);
mockLocation.setAltitude(30);
…
locationManager.setTestProviderLocation(providerString, mockLocat
```

如果程序声明了ACCESS_MOCK_LOCATION，就可以通过上述方法来产生模拟的位置了，从而完成测试目标。